

ANTÔNIO CARLOS FAVA DE BARROS

**DETECÇÃO DE DEFEITOS DE CENOURAS UTILIZANDO
TÉCNICAS DE PROCESSAMENTO DE IMAGENS
DIGITAIS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

VIÇOSA
MINAS GERAIS - BRASIL
2010

**Ficha catalográfica preparada pela Seção de Catalogação e
Classificação da Biblioteca Central da UFV**

T

B277d
2010

Barros, Antônio Carlos Fava de, 1964-

Detecção de defeitos de cenouras utilizando técnicas de
processamento de imagens digitais / Antônio Carlos Fava de
Barros. – Viçosa, MG, 2010.

x, 123f. : il. (algumas col.) ; 29cm.

Orientador: Francisco de Assis de Carvalho Pinto.
Tese (doutorado) - Universidade Federal de Viçosa.
Inclui bibliografia.

1. Processamento de imagens - Técnicas digitais.
2. Análise multivariada. 3. Cenoura - Controle de qualidade.
4. Redes neurais (Computação). I. Universidade Federal de Viçosa. II. Título.

CDD 22. ed. 621.367

ANTONIO CARLOS FAVA DE BARROS

**DETECÇÃO DE DEFEITOS DE CENOURAS UTILIZANDO
TÉCNICAS DE PROCESSAMENTO DE IMAGENS
DIGITAIS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

APROVADA: 9 de dezembro de 2010.

Prof. Jaime Gómez Gil

Prof. Paulo César Corrêa

Prof. Joseph Kalil Khoury Junior

Prof. Daniel Marçal de Queiroz
(Coorientador)

Prof. Francisco de Assis de Carvalho Pinto
(Orientador)

AGRADECIMENTOS

À Universidade Federal de Viçosa e ao Departamento de Engenharia Agrícola, pela oportunidade de realização do curso.

Ao Professor Francisco de Assis de Carvalho Pinto pela orientação, amizade, paciência e confiança.

Ao Professor Daniel Marçal de Queiroz e Professor Nerilson Terra Santos pela amizade e colaboração nas atividades de pesquisa.

À EMBRAPA e à Milza, que muito ajudou na pesquisa e sem esta ajuda, esta tese não existiria.

Aos colegas e amigos da mecanização agrícola: Daniel, Diogo, Enrique, Francelino, Geice, Gislaine, Leonardo, Lorena, Marcelo, Mário, Murilo, Paula, Ronaldo, Samuel, Selma, Sérgio, Wagner, Walter e todos os que conviveram na família Mecanização nestes anos.

Aos professores Delly, Evandro, Haroldo Fernandes, Kalil, Luciano Baião, Mauri Teixeira, Pedro Hurtado e Ricardo Capúcio, pelo apoio e pela troca de experiências.

Aos funcionários do Departamento de Engenharia Agrícola, pela amizade e convívio do dia a dia.

À todo o pessoal da CEDAF- UFV Campus Florestal, que me apoiaram durante este período, em aos professores Calil, Hygor, Walter e Ana, Luíza, José Elias e Ângela, e tantos que estiveram comigo neste período.

Aos meus pais, Lúcio e Meire, irmãos Mara, Luciano e Solange, meus segundos pais Fernando e Sônia, meus segundos irmãos Alarcon e Lara, pelo apoio incondicional na realização deste trabalho.

À minha esposa Flávia, e minhas filhas Juliana e Carolina, por entenderem meu comprometimento com o trabalho, e me apoiarem sempre que ocorreram imprevistos.

BIOGRAFIA

ANTÔNIO CARLOS FAVA DE BARROS, filho de Lúcio Avelino de Barros e Meire Terezinha Fava de Barros, nasceu em Belo Horizonte, MG, no dia 22 de outubro de 1964.

Em 1982 conclui o Curso Técnico em Eletrônica no CEFET-MG, em 1990, graduou-se em Engenharia Elétrica pela PUCMINAS e em 2003 concluiu o Mestrado em Tecnológica, no CEFET-MG.

Em maio de 2006 iniciou o curso de doutorado em Engenharia Agrícola, área de concentração em Mecanização Agrícola, na Universidade Federal de Viçosa, e submeteu-se à defesa de tese em dezembro de 2010.

ÍNDICE

RESUMO.....	vii
ABSTRACT.....	ix
CAPÍTULO 1 INTRODUÇÃO.....	1
1.1. Introdução.....	1
1.2 Aplicações de sistemas de visão artificial (SVA)	2
1.3 Classificação de raízes de cenouras utilizando SVA.....	6
1.4 Objetivos.....	8
1.5 Disposição do trabalho.....	9
1.6 Referências Bibliográficas.....	10
CAPÍTULO 2 SEGMENTAÇÃO DE IMAGENS DE RAÍZES DE CENOURA (<i>Daucus Carota L.</i>) PARA DETECÇÃO DE INCIDÊNCIA DE OMBRO VERDE	13
2.1. Introdução.....	13
2.2. Material e Métodos.....	17
2.3. Resultados e Discussão.....	21
2.4. Conclusões.....	25
2.5. Referências Bibliográficas.....	26
CAPÍTULO 3 CLASSIFICAÇÃO MORFOLÓGICA DE RAÍZES DE CENOURA (<i>DAUCUS CAROTA</i>) UTILIZANDO DESCRITORES TOPOLÓGICOS, ESTATÍSTICOS, DE FOURIER E WAVELETS.....	28
3.1. Introdução.....	28
3.2. Fundamentação Teórica.....	31
Descritores topológicos.....	31
Momentos centrais e momentos invariantes de Hu.....	32
Transformada de Fourier.....	35
Transformada Wavelet.....	38

3.3. Material e Métodos.....	41
Processamento das imagens	42
Cálculo dos descritores geométricos.....	44
Cálculo dos momentos centrais, momentos invariantes de Hu, descritores de Fourier e Wavelet.....	47
Classificação da forma utilizando redes neurais artificiais.....	48
3.4. Resultados e discussão.....	49
3.5. Conclusões.....	56
3.6. Referências Bibliográficas.....	56
CAPÍTULO 4 AVALIAÇÃO DE DESCRITORES DE TEXTURA PARA DETECÇÃO DE RACHADURAS EM RAÍZES DE CENOURAS (<i>Daucus carota</i>)	61
4.1 Introdução.....	61
4.2 Fundamentação Teórica.....	62
Abordagem Estatística – Descritores de Halarick.....	66
Abordagem Espectral.....	69
Classificação de padrões utilizando Redes Neurais Artificiais.....	76
4.3 Material e Métodos.....	79
Recortes das imagens.....	81
4.4 Resultados e Discussões.....	84
Limiarização das imagens.....	84
Abordagem Espectral	86
Abordagem Estatística	90
Classificação das raízes.....	92
4.5 Conclusões.....	93
4.5 Referências Bibliográficas.....	94
CAPÍTULO 5 SISTEMA PARA AQUISIÇÃO DE IMAGENS UTILIZANDO CAMERA LINE-SCAN.....	100

5.1	Introdução.....	100
5.2	Fundamentação Teórica.....	101
	Operação da câmera <i>line-scan</i>	105
5.3	Materiais e Métodos.	108
5.4	Resultados e Discussão.....	111
5.5	Conclusões	117
5.6	Referências Bibliográficas.....	111
CAPÍTULO 6	CONSIDERAÇÕES FINAIS.....	120
6.1	Conclusões.....	120
6.2	Sugestões para trabalhos futuros.....	123

RESUMO

BARROS, Antônio Carlos Fava de, D.Sc, Universidade Federal de Viçosa, dezembro de 2011. **Detecção de defeitos de cenouras utilizando técnicas de processamento de imagens digitais.** Orientador: Francisco de Assis de Carvalho Pinto. Co-orientadores: Daniel Marçal de Queiroz, Nerilson Terra Santos e Milza Moreira Lana.

A inspeção e separação manual de produtos agrícolas para o consumo humano é uma tarefa que além de cansativa é ineficiente, pois o critério de separação pode variar de pessoa para pessoa. A automação de processos de inspeção visual e separação de produtos utilizando sistemas de visão artificial vêm crescendo no mundo todo, sendo utilizados também na classificação de produtos agrícolas. No caso de cenouras, a presença de alguns defeitos considerados como graves resultam no descarte do produto. Neste trabalho, foi estudada a detecção de defeitos graves em cenouras, como a incidência de ombro-verde/roxo, a presença de rachaduras e defeitos no formato. Para realizar a identificação da incidência de ombro verde/roxo, foram utilizados os valores RGB da imagem, aplicados a um classificador utilizando a análise discriminante. Esta metodologia resultou na classificação exata de todas as imagens analisadas, sendo indicada para a separação das raízes que apresentaram este defeito. Para separar as raízes com formato inadequado (tortas) foram desenvolvidos cinco descritores: geométricos, momentos, momentos invariantes, e espectrais baseados nas transformadas de Fourier e de wavelet. Cada grupo foi individualmente aplicado e um classificador baseado em uma rede neural do tipo perceptron, de três camadas. O grupo que apresentou melhores resultados foi o formado pelos descritores geométricos, com exatidão global de 93,3% e um coeficiente kappa de 86,1%. Para detecção de rachaduras em cenouras, foram avaliadas duas metodologias, sendo a primeira utilizando descritores de textura de Halarick (contraste, energia, homogeneidade e correlação) obtidos a partir da matriz de co-ocorrência extraída da imagem monocromática. A segunda metodologia foi baseada no valor de energia das sub-bandas da imagem original, obtidas pela decomposição espectral através da aplicação da transformada de wavelet. Os dois grupos de descritores foram aplicados a um classificador baseado em uma rede neural do tipo perceptron de três camadas. As duas metodologias

apresentaram resultados satisfatórios, sendo que os descritores de textura apresentaram exatidão global de 95%, com coeficiente kappa de 87,5%, e os descritores de energia apresentaram exatidão global de 94,7%, com coeficiente kappa de 88,7%. Foi também avaliada a utilização de uma câmera digital do tipo line scan, que permitiu elevadas taxas de aquisição e transferência de dados. Para capturar todo o contorno da imagem, foram utilizados espelhos planos, que resultaram na distorção da imagem.

ABSTRACT

BARROS, Antônio Carlos Fava de, D.Sc, Universidade Federal de Viçosa, december, 2010. **Detection of defective carrots utilizing digital image processing techniques.** Adviser: Francisco de Assis de Carvalho Pinto. Co-advisers: Daniel Marçal de Queiroz, Nerilson Terra Santos and Milza Moreira Lana.

Manual inspection and separation of agricultural products for human consumption is a task that is not only tiresome but inefficient since separation criterion may vary from person to person. Automation of the visual inspection and product separation processes utilizing machine vision systems has been growing worldwide, also being utilized in classification of agricultural products. In the case of carrots, the presence of some serious defects results in disposal of the product. In this work the detection of severe defects in carrots was studied, including the incidence of the green/purple shoulder, the presence of cracks and defects in shape. For identification of incidence of green/purple shoulder RGB values of the image were used, applied to a classifier using a discriminant analysis. This methodology resulted in the exact classification of all images analyzed, being indicated for the separation carrots with this defect. To separate carrots with an inappropriate shape (crooked), five categories were developed: geometric, moments, invariant moments, and spectral based on Fourier and wavelet transforms. Each group was individually applied and classified based on a three layer perceptron neural network. The group presenting the best results was formed by the geometric factors, with an overall accuracy of 93.3% and a kappa coefficient of 86.1%. For detection of cracks in carrots two methodologies were assessed, the first using Halarick texture features (contrast, energy, homogeneity and correlation) obtained from the co-occurrence matrix extracted from the monochrome image. The second method was based on the energy value of the sub-bands from the original image, obtained by spectral decomposition via application of the wavelet transform. The two groups of descriptive features were applied to a classifier based on a three layer perception neural network. The two methods showed satisfactory results, where the texture features presented overall accuracy of 95% with a kappa coefficient of 87.5%, and the energy factors showed an overall accuracy of 94.7% with kappa coefficient of 88.7%. Also evaluated was the use of a line

scan digital camera, which allowed for elevated rates of data acquisition and transfer. To capture the entire image, flat mirrors were used, resulting in image distortion.

CAPÍTULO 1 – INTRODUÇÃO

1.1 INTRODUÇÃO

Entende-se por classificação como a designação de um produto a uma de várias categorias, como classificar produtos que possuem diferentes características de qualidade, enquanto o termo separação é designado como a tarefa de agrupar os produtos de acordo com características físicas, como tamanho, forma e cor. Desta forma, mesmo os produtos separados tomando-se por base seus aspectos físicos precisam passar por um processo de classificação quanto às normas de qualidade impostas ao produto (HU et al., 1995).

O produtor rural já percebe que é fundamental seguir normas de separação e classificação de seus produtos para evitar que produtos defeituosos cheguem à mesa do consumidor, abalando as relações de confiança entre eles. Também existe a motivação econômica, uma vez que um produto que alcance uma boa classificação certamente terá um preço diferenciado no mercado. Também percebe que só poderá ampliar sua participação no mercado interno e adquirir competitividade para lançar-se ao mercado externo quando disponibilizar seus produtos previamente classificados (FERNANDEZ et al., 2005).

O consumidor, por sua vez, vem se tornando cada vez mais exigente, selecionando produtos que apresentem qualidade e segurança para o consumo. Para produtos agrícolas, a qualidade está associada principalmente às propriedades visuais. Estas propriedades visuais são uma mistura dos atributos de cor, forma e tamanho do produto em questão (PAULUS & SCHEREVENS, 1999).

Os processos de separação e classificação de produtos podem ser realizados manualmente ou por sistemas automáticos. Uma linha de separação manual é dispendiosa no ponto de vista econômico, e por ser realizada por humanos, apresenta diversos problemas de operação. A fadiga e outros fatores psicológicos associados com o pessoal envolvido em um processo de inspeção

manual degradam o desempenho desses funcionários, o que pode resultar em erros de inspeção. Mais importante ainda, o desempenho dos inspetores humanos geralmente é subjetivo e variável, uma vez que estes, apesar de seguirem normas de classificação, poderão ter seu próprio padrão de inspeção e classificação de produtos e defeitos, influenciados pelo cansaço ou por motivos que interfiram no seu julgamento. Assim, é possível que inspetores diferentes possam classificar um mesmo produto em diferentes classes. Além disso, um único inspetor humano pode fazer julgamentos diferentes sobre o mesmo produto em diferentes instâncias (BATCHELOR & WHELAN, 2002). Segundo Gunasekaran (1996), todos estes inconvenientes tornam a inspeção manual uma atividade tediosa, trabalhosa, inconsistente e demorada, tornando-a assim inadequada para atender a demanda.

Desta forma, os sistemas de inspeção manuais vêm sendo gradativamente substituídos na indústria por processos automáticos de inspeção. Os sistemas de visão artificial (SVAs) são exemplos de tecnologia para automação da inspeção, disponibilizando métodos rápidos, econômicos, consistentes e objetivos, não destrutivos e não invasivos, e com acurácia superior à classificação humana (BROSNAN & SUN, 2002).

1.2 APLICAÇÕES DE SISTEMAS DE VISÃO ARTIFICIAL

Os SVAs são uma tecnologia relativamente nova, sendo que somente na década de 90 foi dado um maior impulso na utilização destes sistemas na indústria (BATCHELOR & WHELAN, 2002). Um SVA pode ser definido como uma área da engenharia que realiza a integração da mecânica-ótica-eletrônica-informática para examinar materiais, naturais ou produzidos pelo homem, de maneira a detectar defeitos e prover qualidade, eficiência operacional e segurança para todo o processo (GRAVES & BATCHELOR, 2004).

Os SVAs são constituídos de sub-sistemas de captura, processamento e análise de imagens, facilitando a avaliação objetiva e não-destrutiva das características de qualidade visual. Os recentes avanços em hardware e software têm auxiliado nessa expansão, fornecendo soluções de baixo custo, e incentivando as pesquisas nesta área. Estes sistemas oferecem baixa relação

custo/benefício, além de apresentarem boa repetibilidade, velocidade de processamento e precisão na classificação superiores em relação aos sistemas manuais.

Segundo Davies (2009), a inspeção de alimentos é uma das melhores aplicações dos SVAs, não somente para alimentos processados e suas embalagens, mas também para os alimentos na sua forma original, como hortaliças e frutas. As aplicações desenvolvidas podem utilizar somente o espectro visível, ou combinadas com sistemas sensíveis ao infra-vermelho próximo ou até mesmo sistemas mais avançados, como os que utilizam sensores hiper-espectrais ou aparelhos de raio-X.

No processo de classificação, são analisados diversos fatores, como o formato do produto, a presença ou não de defeitos na superfície, a cor, textura e outros. A inspeção de defeitos na superfície é uma das aplicações mais utilizadas, em que a partir da imagem obtida, são geradas imagens segmentadas, onde os defeitos são destacados.

Por ser uma fruta de grande valor econômico, e cultivada no mundo todo, a inspeção de maçãs utilizando SVA vem merecendo destaque na literatura. Para detectar defeitos na superfície de maçãs, Leemans et al. (1999) utilizaram um classificador bayesiano na segmentação de imagens de maçãs da variedade 'Jonagold'. A distribuição de frequência das cores das regiões com e sem defeitos foram utilizadas para estimar a distribuição de probabilidade de cada classe. Para avaliar o resultado da classificação, adotaram qual a porcentagem da área de uma fruta sem defeito foi reconhecida como defeito. Para avaliar o sistema, foi selecionado um grupo de teste composto de frutas saudáveis, sem defeito na superfície. O sistema detectou identificou erroneamente que 69% destes frutos saudáveis apresentavam defeitos que atingiam até de 5% da área da superfície. Os autores concluíram que a confusão ocorrida entre os frutos saudáveis e os que apresentaram defeito se devem principalmente a ocorrência natural de manchas castanho-avermelhado na superfície, que foram reconhecidos erroneamente como defeitos.

Bennedsen et al. (2005) utilizaram um mecanismo para rotacionar as maçãs, acoplados a câmeras digitais com filtros de 750nm e 900nm, e obtiveram imagens de todo o contorno dos frutos. Foram utilizadas três técnicas de segmentação, sendo a primeira para correção de brilho na imagem, a segunda para identificar pontos mais escuros da imagem original e a última para detecção dos defeitos. Utilizando estas técnicas, os autores conseguiram identificar 92% dos defeitos presentes em maçãs do tipo 'Pink Lady'.

A partir de 46 imagens espectrais tomadas na faixa de 650nm a 1100nm, com intervalos de 10nm, Vijayarekha (2009) utilizou técnicas de análise multivariada para detectar defeitos nas superfícies de maçãs. Aplicando análise de componentes principais, reduziu o número de imagens, eliminando aquelas que apresentaram grandes variações. Nas imagens restantes, traçou os dois primeiros componentes principais um contra o outro, formando um histograma bidimensional dos valores dos escores. Desta forma, os pixels com características espectrais semelhantes são traçados próximos um do outro, não importando a posição na imagem original. O histograma traçado foi utilizado como referencia para segmentar estas imagens.

Barnes et al. (2010) desenvolveram um algoritmo para detecção de defeitos em batatas a partir de imagens de teste, que foram adquiridas em laboratório. Foram capturadas imagens em seis diferentes tamanhos, que foram transformadas para se obter sete canais de cores (RGB, RGB normalizado e a monocromática). De cada uma destas imagens, foram extraídos três momentos estatísticos e três descritores de borda, resultando inicialmente em 378 características. Estas foram adicionadas com as vinte e uma características obtidas diretamente dos valores de pixels, totalizando 399 características. Utilizando um algoritmo AdaBoost, que é um algoritmo genérico de aprendizagem de máquinas para construção de classificadores complexos a partir de classificadores simples, os autores selecionaram apenas 10 destas características, obtendo taxas de sucesso de 89,6 % e 89,5.% para batatas brancas e vermelhas, respectivamente.

O formato é outro diferencial que determina a preferência de um consumidor pelo produto. Para representar o formato de objetos, os descritores

mais utilizados são os descritores geométricos, que são compostos por medidas ou relações geométricas do formato obtido, como perímetro, área, diâmetro, relações entre maior e menor eixo, convexidade, e outras medidas específicas para cada aplicação.

Nakata & Tallada (2008) definiram cinco eixos paralelos dispostos ao longo do comprimento de morangos, e usaram as medidas de distância euclidiana entre o ponto médio destes eixos e um ponto no extremo para classificar os frutos em quatro variedades. Foram utilizadas 546 amostras dos frutos e o vetor resultante foi aplicado a uma rede neural de três camadas, obtendo resultados de 94% a 98% de acertos.

Outro descritor de forma que tem destaque na literatura são as funções de assinatura do contorno. Estas funções podem ser obtidas através das medidas de distância do centróide aos pontos do contorno do objeto, ou uma função da variação do diâmetro ao longo do comprimento ou ainda uma outra função qualquer extraída do formato do objeto, resultando na conversão da imagem $I(x,y)$ em uma função $f(x,y)$, mais simples de ser descrita. A partir desta função $f(x,y)$, podem-se obter transformações para extrair outros descritores de forma, como os obtidos pela aplicação das transformadas de Fourier e de Wavelet (GONZALEZ & WOODS, 2000).

Utilizando a transformada de Fourier aplicada à assinatura do contorno, associados aos descritores geométricos (fator de forma, índice de alongamento, comprimento, área e simetria), Blasco et al. (2009) desenvolveram um protótipo para separar gomos de tangerinas, destinados à industrialização. Como classificador, utilizaram um classificador bayesiano típico. Aplicando somente os dez primeiros harmônicos da transformada de Fourier, obtiveram uma taxa de acertos de apenas 36%. Associando com os descritores geométricos, obtiveram uma melhoria, com 92,3% de acertos na separação dos gomos defeituosos.

Horgan (2001) utilizou a metodologia de extração de coordenadas de pontos específicos (landmarks) para diferenciar cultivares de cenouras quanto ao formato do ápice e ombro da raiz. O método foi considerado insatisfatório

devido às variações do formato que ocorrem dentro de um grupo de raízes pertencentes ao mesmo cultivar.

Horgan et al. (2001) utilizaram imagens de folhagem e de raízes de cenoura para identificar diferentes cultivares. Foram tomadas imagens das raízes inteiras e fatiadas ao longo do comprimento da raiz, de onde foram extraídas medidas simples, como o comprimento e largura da raiz, e um critério de pontuação subjetiva (por características como cor e curvatura). Utilizando estas características para classificar quinze diferentes cultivares, os autores obtiveram uma taxa de 64% de acertos para cultivares produzidos no mesmo ano. Ao agrupar cultivares que apresentavam forte semelhança, a taxa de acertos subiu para 58%.

Outro trabalho utilizando SVAs aplicados à cenouras foi desenvolvido por Hahn & Sanches (2000), que utilizaram imagens monocromáticas para estimar o volume de raízes de cenoura. O sistema utilizado gira a câmera ao redor da raiz, tomando imagens de todo o contorno. O algoritmo desenvolvido pelos autores calcula diferentes diâmetros tomados ao longo do comprimento da raiz, estimando assim o volume desta. Os resultados foram satisfatórios, atingindo uma correlação de 0.98 entre o volume estimado e o real.

Estas pesquisas realizadas incentivam a realização de novos trabalhos na área de classificação automática de produtos hortigranjeiros utilizando sistemas de visão artificial, visando à substituição da mão-de-obra humana pelos sistemas automáticos. Porém, estes trabalhos focam em defeitos específicos, isolados, como manchas na superfície ou no formato, não tendo sido tratados diferentes defeitos em um mesmo trabalho.

1.3 CLASSIFICAÇÃO DE RAÍZES DE CENOURAS UTILIZANDO SISTEMAS DE VISÃO ARTIFICIAL

A cenoura (*Daucus carota L.*) é uma hortaliça da família Apiaceae ou Umbelífera originária da região onde hoje se localiza o Afeganistão. A parte comestível é uma raiz pivotante com elevado teor de betacaroteno (FILGUEIRA, 2000). O ciclo fenológico da cenoura, da semeadura até a colheita varia de 85 a 125 dias, dependendo da cultivar, do clima e da época de

colheita. A cenoura figura entre as cinco espécies olerícolas de maior importância econômica no Brasil e a terceira no mundo (MEDEIROS, 2006), sendo o estado de São Paulo o maior produtor, com safra em 2006 de 103.426.775 kg, (TSUNECHIRO, 2007), seguido por Minas Gerais. Em São Paulo, 75% da produção está concentrada nas cidades de São José do Rio Pardo, Mogi das Cruzes, Piedade e Suzano (IEA-SP, 2010). Em Minas Gerais os maiores produtores são os municípios de São Gotardo, Rio Paranaíba e Carandaí, que juntos foram responsáveis por aproximadamente 85% de toda cenoura transacionada no mercado mineiro em abril/2006, indicando assim a concentração da cultura nesta região. A produção de cenoura é estimada no Brasil em 6 milhões de toneladas (BEIRIGO et al., 2009).

Porém, como em todo produto agrícola, a produção de cenoura apresenta um produto final não uniforme. São comercializados diferentes cultivares, que por sua vez apresentam diferentes tamanhos e defeitos, ocasionando assim diferentes níveis de aceitação no mercado consumidor.

Em 1997, surgiu um programa de adesão voluntária e de autoregulamentação setorial, como Programa Paulista para a Melhoria dos Padrões Comerciais e de Embalagens de Hortigranjeiros, fruto da decisão da Câmara Setorial de Frutas e da Câmara Setorial de Hortaliças, Cebola e Alho da Secretaria de Agricultura e Abastecimento do Estado de São Paulo. Em 2000, atendendo à demanda de outros estados brasileiros, tornou-se um programa de atuação nacional. A atual denominação se deve à necessidade de uma ação mais profunda e abrangente de modernização da cadeia de produção de frutas e hortaliças frescas. O Centro de Qualidade em Horticultura da CEAGESP é o responsável pela operacionalização do Programa desde o seu início. Já em 2002, o Instituto Mineiro de Agropecuária – IMA, através da portaria nº 488, de 5 de fevereiro de 2002, estabeleceu os padrões de qualidade para cenoura a serem implantados em Minas Gerais.

Nesta padronização do IMA (2002), foram determinadas quatro classes, de acordo com o comprimento e diâmetro da raiz; e quatro categorias, de acordo com a presença de defeitos (podridão mole, deformação, podridão

seca, ombro verde/roxo, lenhosa, murcha, rachada, com dano mecânico ou injúria por pragas ou doenças).

Após colhidas, as raízes passam por linhas de lavagem e inspeção, onde são realizadas as tarefas de separação e classificação do produto, onde são separadas conforme as classes determinadas e descartadas as raízes que apresentem defeitos graves. Alguns sistemas mecânicos são utilizados para realizar a lavagem e uma separação por diâmetro, realizado através de roletes com espaçamentos, onde as raízes com diâmetro inferior a um padrão são separadas.

A utilização de SVAs para a realização das tarefas de classificação e separação das raízes permitiria uma menor subjetividade, maior velocidade de operação, menor custo para o produtor/cooperativa e, para o consumidor, o fornecimento de um produto de acordo com as normas de padronização.

1.4 OBJETIVOS

Este trabalho teve como objetivo geral desenvolver algoritmos utilizando técnicas de processamento de imagens digitais para detectar defeitos em cenouras seguindo padrões determinados pelo Instituto Mineiro de Agropecuária - IMA.

Os objetivos específicos foram:

- Desenvolver algoritmos para detecção da incidência de ombro verde/roxo em raízes de cenoura, e determinar o comprometimento do comprimento da raiz que é afetado por este defeito;
- Desenvolver algoritmos para detecção de defeitos no formato de raízes de cenouras, visando identificar raízes com comprimento e diâmetro fora do permitido pela norma;
- Desenvolver algoritmos para detecção de defeitos no formato de raízes de cenouras, visando identificar raízes com formato aceitável para comercialização;

- Desenvolver algoritmos para identificar defeitos na superfície da cenoura, provocado por rachaduras;
- Avaliar o desempenho de rotinas implementada em linguagem C utilizando a biblioteca de software livre OpenCV;
- Avaliar o desempenho de um sistema de aquisição de imagens utilizando uma câmera *line-scan* com alta taxa de aquisição e transferência de dados;
- Avaliar o desempenho do sistema de aquisição de imagens utilizando espelhos refletores, de forma a obter imagens de todo o contorno da raiz.

1.5 DISPOSIÇÃO DO TRABALHO

O trabalho foi dividido em 6 capítulos. O primeiro apresenta uma breve descrição dos tópicos abordados nos outros capítulos.

No segundo capítulo são avaliados os defeitos decorrentes da incidência de ombro verde/roxo nas raízes. Segundo os padrões definidos pelo IMA(2002), a raiz que apresenta mais de 10% do comprimento comprometida com a incidência de ombro verde deverá ser descartada. Para realizar a segmentação das imagens, foi implementado um classificador baseado na função linear discriminante. Para avaliar a velocidade de processamento das imagens, foi desenvolvido um programa em linguagem C++ utilizando a biblioteca de processamento de imagens OpenCV, que é disponível em código livre.

O terceiro capítulo apresenta uma avaliação comparativa de descritores de forma para classificação morfológica de raízes de cenouras. Foram utilizados os descritores geométricos (altura, largura, centro, centróide, esfericidade, e de irregularidades) descritores espectrais obtidos a partir da transformadas de Fourier e Wavelet aplicadas à função do contorno das raízes, momentos centrais e de Hu. Foram utilizadas técnicas de análise multivariada para selecionar os melhores descritores, que foram aplicados em um classificador baseado em redes neurais artificiais.

O quarto capítulo apresenta a identificação de rachaduras na superfície de raízes de cenouras. Foram utilizados descritores de textura de Halarick e descritores de energia derivados das imagens subamostradas obtidas após a aplicação da transformada wavelet para identificar as rachaduras e realizar a separação das raízes defeituosas.

O quinto capítulo apresenta o desenvolvimento do sistema de aquisição de imagens utilizando uma câmera line-scan, com a utilização de espelhos refletores para adquirir imagens de todo o contorno da raiz. São verificadas a calibração da câmera, a configuração da taxa de aquisição de dados e a resolução das imagens obtidas, de forma a avaliar a possibilidade de um sistema de visão que realize a classificação das imagens das raízes de cenoura em tempo-real.

O sexto capítulo apresenta um resumo geral e sugestões para trabalhos futuros.

1.6 REFERÊNCIAS BIBLIOGRÁFICAS

BARNES, M.; DUCKETT, T.; CIELNIAK, G.; STROUD, G. HARPER, G. **Visual detection of blemishes in potatoes using minimalist boosted classifiers.** Journal of Food Engineering, v.98, n.3, p.339-346. 2010.

BATCHELOR, B., WHELAN, P.F. *Intelligent Vision Systems for Industry*, Minnesota, USA: Batchelor and Whelan Ed., 2002.

BEIRIGO, J. D. C. ; SANTANA, M. J. ; VIEIRA, T. A. Função de produção da cultura da cenoura para diferentes lâminas de irrigação. In: II Seminário Iniciação Científica do IFTM, 2009, Uberaba, MG. Anais do II SIC, 2009.

BENNEDSEN, B.S; PETERSON, D.L.; TABB, A. **Identifying defects in images of rotating apples.** Computers and Electronics in Agriculture. 48: 92-102. 2005.

BLASCO, J.; ALEIXOS, N.; CUBERO, S.; GÓMEZ-SANCHÍS, J. MOLTÓ, E. **Automatic sorting of satsuma (Citrus unshiu) segments using computer vision and morphological features.** Computers and Electronics in Agriculture, v.66, n.1, p.1-8. 2009.

BROSNAN, Tadhg; SUN, Da-Wen. Inspection and grading of agricultural and food products by computer vision systems-review. **Computers and Electronics in Agriculture**. 36: 193-213. 2002.

CEAGESP. Programa brasileiro para a melhoria dos padrões comerciais e embalagens de hortifrutigranjeiros: Classificação da cenoura: programa de adesão voluntária. CEAGESP: *Centro de qualidade em horticultura*, São Paulo, 2000.

DAVIES, E. R. **The application of machine vision to food and agriculture: a review**. *Imaging Science Journal*, The, v.57, p.197-217. 2009.

FILGUEIRA, F. A. R. **Novo manual de olericultura: Agrotecnologia moderna na produção e comercialização de hortaliças**. Viçosa, UFV, 2000. 402 p.

FERNÁNDEZ, L.; Castillero; A; AGUILERA, J.M. An application of image analysis to dehydration of apple discs, **Journal of Food Engineering**. 67: 185–193. 2005.

GONZALEZ, R.C.; WOODS, R.E. **Processamento de imagens digitais**. São Paulo: Editora Edgard Blücher Ltda, 2000. 509p.

GUNASEKARAN, Sundaram. Computer vision technology for food quality assurance. **Trends in Food Science & Technology August**. 7: 245-256. 1996.

GRAVES, M; BATCHELOR, B. **Machine vision for the inspection of natural products**. 1 ed. New York: Springer-Verlag New York, Inc., 2003. p.457.

HAHN, F.; SNACHEZ, S. **Carrot volume evaluation using image algorithms**. *Journal of Agricultural Engineering Research*, vol 73, n. 3, p. 243-249, 2000.

HORGAN, G. W.; TALBOT, M. DAVEY, J. C. **Use of statistical image analysis to discriminate carrot cultivars**. *Computers and Electronics in Agriculture*, v.31, n.2, p.191-199. 2001.

HORGAN, G.W. **The statistical analysis of plant part appearance - a review**. *Computers and Electronics in Agriculture*. 31, n.2, pp. 169–190. 2001.

HU, B.-G.; GOSINE, R.G.; SILVA, C.W. Classifier design for computer grading systems for food processing. In: **IEEE INTERNACIONAL CONFERENCE ON**

SYSTEMS, MAN AND CYBERNETICS, 1995, Vancouver. **Anais...Vancouver**, 1995. p. 730-735

HU, B. G.;GOSINE, R. G. DE SILVA, C. W. Classifier design for computer grading systems for food processing. Systems, Man and Cybernetics, 1995. Intelligent Systems for the 21st Century., IEEE International Conference on. 22-25 Oct 1995, 1995. 730-735 vol.1 p.

IEA – Instituto de Economia Agrícola do Estado de São Paulo. Disponível em: <http://www.iea.sp.gov.br>. Acesso em 05 de mar. 2010.

IMA. PORTARIA Nº 488, DE 5 DE FEVEREIRO DE 2002. Estabelece padrões para cenoura destinada a certificação de origem e qualidade.

LEEMANS, V.;MAGEIN, H. DESTAIN, M. F. **Defect segmentation on Jonagold' apples using colour vision and a Bayesian classification method**. Computers and Electronics in Agriculture, v.23, n.1, p.43-53. 1999.

LUENGO, R. F. A.; CALHO, A. G.; LANA, M. M.; MORETTI, C. L; HENZ, G. P. **Classificação de hortaliças** – Brasília: Embrapa Hortaliças, **1999**.

MEDEIROS, E. M.; BAUDET, L.; PERES, W. B.; PESKE, F. B. Recobrimento de sementes de cenoura com aglomerante em diversas proporções e fungicida. **Revista Brasileira de Sementes**. 28: 94-100. 2006.

NAGATA, M.; TALLADA, J. G . **Quality Evaluation of Strawberries**. Computer Vision Technology for Food Quality Evaluation, v. 1, n.1, p. 265-287, 2008.

PAULUS, I. SCHREVEENS, E. **Evaluating and Modelling the Size Classification of Apples**. Journal of Agricultural Engineering Research, v.74, n.4, p.411-419. 1999.

RASHIDI, M; SEYFI, KEYVAN. **Classification of fruit shape in cantaloupe using the analysis of geometrical attributes**. World Journal of Agriculturas Sciences. V 3, n. 6, p. 735-740. 2007

TSUNECHIRO, Alfredo *et al*. Valor da produção agropecuária do estado de São Paulo em 2006. **Informações Econômicas**, SP, v.37, n.4, abr. 2007.

VIJAYAREKHA, K. Multivariate image analysis for defect identification of apple fruit images. Industrial Electronics, 2008. IECON 2008. 34th Annual Conference of IEEE. 10-13 Nov. 2008, 2008. 1499-1503 p.

CAPÍTULO 2 SEGMENTAÇÃO DE IMAGENS DE RAÍZES DE CENOURA (*Daucus Carota* L.) PARA DETECÇÃO DE INCIDÊNCIA DE OMBRO VERDE

2.1 INTRODUÇÃO

No Brasil, o Decreto nº 6.268, de 22 de Novembro de 2007 torna obrigatória a classificação de vegetais e seus subprodutos, quando estes são destinados à alimentação humana. Esta classificação determina a qualidade intrínseca e extrínseca de um produto agrícola. No caso de cenouras (*Daucus carota*), foi adotada uma cartilha de classificação distribuída pela Companhia de Entrepósitos e Armazéns Gerais de São Paulo - CEAGESP (1998) - dividindo a raiz de cenoura em quatro classes, de acordo com o comprimento da raiz; em grupos, de acordo com o cultivar; e em quatro categorias, de acordo com os defeitos apresentados. Já em 2002, o Instituto Mineiro de Agropecuária – IMA, através da portaria nº 488, de 5 de fevereiro de 2002, estabeleceu os padrões de qualidade para cenoura a serem implantados em Minas Gerais, seguindo a padronização sugerida pelo CEAGESP.

Segundo Lana (2000), o consumidor tem preferência por raízes firmes, com cor laranja intensa, com comprimento e diâmetro variando respectivamente entre 15 a 20 cm e 3 a 4 cm e sem pigmentação verde ou roxa na parte superior (ombro). Raízes maiores têm menor qualidade, pois são mais fibrosas e menos saborosas.

A ocorrência de pigmentação na região do ombro é denominada de ombro verde ou ombro roxo, e é um dos defeitos presentes na cenoura que altera o aspecto visual e a palatabilidade. A presença do ombro verde é considerada um distúrbio fisiológico causado pela síntese de clorofila na base da raiz e da coroa, tornando a parte superior da cenoura de cor esverdeada ou arroxeadas. Pode ser causado pelo rebaixamento dos canteiros e exposição aos raios solares, em cenouras colhidas tardiamente, em plantas que tenham reduzida massa foliar ou quando se adota espaçamento entre plantas inferior ao recomendado (FINGER et al., 2005).

Segundo a norma de classificação definida pelo IMA (2002), devem ser descartadas as raízes que apresentarem incidência de ombro verde ou roxo representando mais de 10% do comprimento. Para realizar esta avaliação, após a colheita, as raízes são lavadas e separadas manualmente. Estes processos manuais são tediosos, trabalhosos, inconsistentes e demorados (Gunasekaran,1996). Além disto, é subjetivo, pois cada profissional envolvido no processo pode analisar de forma diferente um mesmo produto, classificando-o em categorias diferentes.

Para suprir a falha e a subjetividade da operação humana, os sistemas de visão artificial (SVAs) vêm sendo empregados com sucesso na classificação de produtos agrícolas, disponibilizando métodos rápidos, econômicos, consistentes, objetivos, não destrutivos e com acurácia superior à classificação humana (BROSNAN & SUN, 2002). Alguns exemplos de SVAs para classificação de produtos agrícolas são: maçãs (YANG, 1996; LEEMANS & DESTAIN, 2004; BENNEDSEN et al., 2005; REGUNATHAN, 2005), cítricos (KONDO, 2000; SIMÕES, 2003) e tomates (JAHNS et al., 2001; LOURO, 2006).

Os SVAs são constituídos de uma ou mais câmeras conectadas a placas de aquisição de imagens e controlados por softwares, que podem ser desenvolvidos em plataforma específica, utilizando processadores digitais de sinais (DSP's), ou através de programas executados em plataforma IBM-PC, utilizando uma linguagem de programação otimizada, como a linguagem C. A complexidade do sistema aumenta de acordo com a necessidade do detalhamento das informações a serem obtidas, com a velocidade necessária para a aquisição e processamento e com o número de bandas a serem fornecidas pelas câmeras.

Após a aquisição, as imagens devem ser processadas para extrair as informações de interesse, de acordo com a aplicação sendo realizada. Podem ser informações de cor, textura, forma e outras. Uma das técnicas de processamento de imagens utilizada é a segmentação, que consiste no processo de dividir uma imagem digital em múltiplas regiões, baseados em um conjunto de pixels ou objetos, destacando assim as áreas de interesse e

facilitando a sua análise. Como resultado, cada um dos pixels com determinada similaridade é agrupado em uma mesma região. Esta similaridade é alguma característica ou propriedade extraída da imagem digital, tal como cor, intensidade, textura ou continuidade. Uma das técnicas de segmentação disponíveis é a detecção de pontos, onde cada pixel da imagem é lido e classificado como pertencente a uma região. Os classificadores para realizar tal operação podem ser implementados utilizando métodos supervisionados ou não-supervisionados. Um tipo de classificador supervisionado são as funções discriminantes, enquanto que as técnicas de agrupamento, como o algoritmo K-means, são exemplo de classificadores não-supervisionados.

A função discriminante quadrática é uma técnica supervisionada que parte do pressuposto que as matrizes de médias e covariâncias foram obtidas previamente, extraídas a partir de imagens de teste. Dentre os problemas desta técnica, está a necessidade de se obter o maior número possível de amostras, permitindo uma maior variância dos dados, evitando assim a singularidade da matriz de covariância presente na equação 1. Outro problema é a pressuposição da homocedasticidade gaussiana da distribuição de cada classe, nem sempre presente no mundo real (FEIPING et al., 2007).

Apesar de ser uma técnica de segmentação do tipo supervisionada e de segmentação pixel a pixel de imagens digitais, a análise discriminante tem sido utilizada em sistemas de classificação on-line, como o sugerido por Leemans e Destain. (2004).

A função discriminante quadrática para k populações com distribuição normal multivariada, é dada por (JOHNSON & WICHERN, 1998):

$$D_j(X) = -\frac{1}{2}(X - \bar{X}_j)' \left(\hat{\Sigma}_j \right)^{-1} (X - \bar{X}_j) - \frac{1}{2} \ln |\hat{\Sigma}_j| + \ln[P(w_j)] \quad 1)$$

Em que:

$D_j(X)$ é o valor da função discriminante quadrática da classe w_j dado X ;

X é o vetor de descritores de um objeto;

\bar{X}_j é o vetor de média da classe j ;

$\hat{\Sigma}_j$ é a estimativa da matriz de co-variância da classe j ;

$P(w_j)$ é a probabilidade a prior de ocorrência da classe j .

Para k classes definidas previamente na imagem, o vetor de características $X'=[x_1, x_2, x_3... x_n]$ será classificado dentro da j -ésima classe se:

$$D_j(X') = \max_{j=1..k} [D_j(X')] \quad (2)$$

Para avaliar um classificador, utiliza-se a exatidão global e a matriz de confusão, que apresenta a porcentagem de acertos e erros de omissão e comissão de cada classe. Um exemplo da utilização da matriz de confusão para avaliar um SVA pode ser encontrado em Blasco et al. (2009), em um sistema de detecção de defeitos em gomos de tangerinas.

De acordo com Watanabe et al. (2007), a velocidade de processamento é fundamental para a automação de uma linha de classificação de produtos, é ideal que o sistema trabalhe em tempo real, sendo recomendada a utilização de processadores digitais de sinais (DSP's). Porém, sistemas automatizados utilizando microcomputadores IBM-PC com uma linguagem otimizada, como o C++, também podem atingir o desempenho desejado.

Associada a uma biblioteca de processamentos de imagens, os programas desenvolvidos em C++ podem ser executados em microcomputadores atingindo desempenho suficiente para o processamento de imagens em alta velocidade. A OpenCV é uma biblioteca de processamento de imagens inicialmente distribuída pela INTEL e posteriormente liberada para desenvolvimento como software livre. Esta biblioteca possui comandos de acesso e tratamento de imagens, permitindo o desenvolvimento de aplicativos em linguagem C, tanto para ambiente Windows como Linux. Estão disponíveis na OpenCV alguns métodos de acesso aos pixels da imagem digital, denominados de método direto e método indireto. No método direto, os pixels

são acessados através de um comando disponível na biblioteca, varrendo a imagem pixel a pixel. No método indireto, é criado wrapper (empacotamento de instruções) que permite o acesso indireto à matriz de pixels da imagem. Este método, também chamado de método de delegação, permite chamar uma segunda função com menor custo computacional, que realiza um determinado processamento, e, segundo Bradski e Kaehler (2007), o método indireto é mais seguro e mais rápido.

Os objetivos deste trabalho foram desenvolver um classificador baseado em funções discriminantes para detectar a incidência de ombro verde e ombro roxo em raízes de cenoura, utilizando os valores RGB de imagens digitais, e avaliar o desempenho da rotina implementada em linguagem C utilizando a biblioteca de software livre OpenCV.

2.2 MATERIAL E MÉTODOS

A parte inicial do trabalho foi realizada na Embrapa Hortaliças, em Brasília. Foram adquiridas 60 imagens digitais de raízes de cenoura utilizando uma câmera DBK41B, da The Imaging Source, com interface USB, e o software de captura IC Capture. Destas imagens, 20 são de cenouras sadias, 20 de cenouras com pigmentação cobrindo menos de 10% do comprimento da raiz e 20 imagens com pigmentação em mais de 10% do comprimento da raiz. As cenouras foram colocadas em uma câmara de iluminação composta de seis lâmpadas fluorescentes PHILIPS de uso comum, de 40 watts cada, forrada internamente com fórmica cinza fosca.

As imagens obtidas foram processadas no Laboratório PROVISAGRO, da Universidade Federal de Viçosa, Viçosa-MG. O programa de segmentação foi implementado em um compilador C de licença livre, o Dev-Cpp, utilizando a biblioteca de processamento de imagens OpenCV, executado em ambiente Microsoft Windows.

Devido à posição das lâmpadas, durante a aquisição das imagens ocorreram sombras nas regiões próximas à raiz. Desta forma, o fundo da imagem foi dividido em duas classes, uma denominada de “fundo escuro”,

representando a região de sombras, e o resto da região do plano de fundo afastado das raízes foi chamado de “fundo claro”.

O trabalho foi dividido em duas etapas. Na primeira etapa, foram utilizadas amostras de pixels das cinco classes para definição dos parâmetros do classificador estatístico, e na segunda etapa, as imagens de raízes de cenouras foram aplicadas ao classificador para detecção do ombro roxo/verde e para separação das raízes de acordo com o comprimento da cenoura que é comprometido por esta anomalia.

Para a implementação dos classificadores, foram selecionadas 10 imagens, sendo que cinco apresentavam incidência de ombro verde e as outras cinco apresentavam incidência de ombro roxo. De cada imagem, foram retirados aleatoriamente 200 pixels de cada uma das cinco classes utilizadas: fundo claro (FC), fundo escuro (FE), cenoura (CE), ombro verde (OV) e ombro roxo (OR). Estes valores foram agrupados, formando os vetores de características $X_j=(R_j, B_j, G_j)$, onde R,G e B representam as do espaço de cor RGB, e $j=1...5$, representando cada uma das classes. Este vetor foi novamente dividido igualmente em dois, sendo a primeira parte utilizada para calcular os parâmetros da função discriminante e a segunda parte para a validação do classificador.

Para verificar se existe separabilidade entre as classes, foi utilizado o teste T^2 de Hotelling. Este teste é aplicado para verificar a igualdade dos vetores médios de populações multivariadas, indicando se a diferença entre as médias das classes é significativa (REGAZZI, 2000). Caso o valor seja significativo, as classes possuem médias diferentes, incentivando então o desenvolvimento de um classificador para separar as classes.

O cálculo dos parâmetros do classificador baseado na função discriminante quadrática foi realizado utilizando a rotina PROC DISCRIM do SAS. A partir do cálculo destes parâmetros, foi posteriormente implementado um programa em linguagem C, para avaliação da velocidade de processamento durante a classificação das imagens.

Os programas foram executados em um microcomputador com processador Intel Pentium Duo Core, de modelo E2180, com frequência de 2.00 GHz e 2 Gb de memória RAM. O programa desenvolvido lê a imagem de teste do disco rígido, realiza a segmentação e exibe a imagem original e o resultado da classificação. Para avaliar a velocidade de processamento, foram utilizados quatro diferentes resoluções de imagens. Para medição da velocidade de processamento, obteve-se o número de ciclos consumido pelo processador na execução do programa, que depois foi transformado em segundos. A contagem do tempo foi iniciada após a leitura da imagem do disco e encerrada após a apresentação da imagem segmentada na tela do computador e fornecido o resultado da classificação, informando se a raiz deve ser descartada ou não.

Para determinação do comprimento da raiz que é afetada pela variação de coloração no ombro, a imagem foi segmentada utilizando a função discriminante quadrática, criando uma imagem com três regiões: fundo, raiz e ombro verde/roxo. O processo de segmentação resulta em regiões com bordas irregulares, o que dificulta a medida do comprimento da região afetada pela pigmentação. Para minimizar este problema, foram tomadas três medidas de comprimento da região afetada, iniciando na extremidade do ombro e finalizando na borda da região de transição da região afetada e da região sadia da raiz. Inicialmente, foi calculado o centróide (C) da região afetada e traçada uma linha vertical, representando o diâmetro da raiz neste ponto, conforme figura 1.



Figura 1. Definindo o centróide (C) da região afetada pelo ombro verde/roxo.

Foram tomados 3 pontos eqüidistantes neste diâmetro, a 25%, 50% e 75% do diâmetro, e traçadas 3 retas ortogonais ao diâmetro, representando o comprimento da região afetada em cada um dos pontos, conforme figura 2.




Figura 2. Determinando três medidas de comprimentos (C_1 , C_2 e C_3) da região afetada.

O sistema desenvolvido calcula os três comprimentos C_1 , C_2 e C_3 , e considera o maior valor dentre eles como o comprimento do ombro verde/roxo, seguindo o algoritmo apresentado na figura 3. O sistema calcula também a porcentagem de incidência do ombro verde/roxo (R_{afet}) calculando a razão entre a maior das três medidas e o comprimento linear da raiz (C_L), de acordo com a equação 3.

$$R_{afet} = \frac{\text{maior}(C_1, C_2, C_3)}{C_L} \quad (3)$$

Se o comprimento da área afetada pela incidência do ombro verde ou roxo atingir um valor maior do que 10% do comprimento da raiz ($R_{afet} > 10\%$), esta será descartada. As imagens foram visualmente analisadas e classificadas, e comparadas com o resultado obtido pelo classificador.

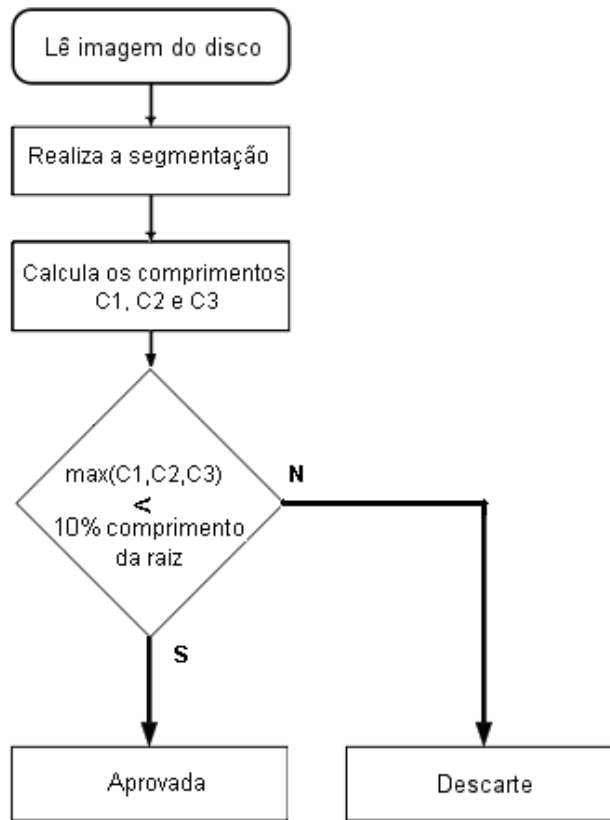


Figura 3. Algoritmo de descarte de cenouras que apresentam incidência de ombro verde atingindo mais de 10% do comprimento da raiz

2.3 RESULTADOS E DISCUSSÃO

No Quadro 1 são apresentados os valores de F calculado para o T^2 de Hotelling dos vetores de médias da cinco classes estudadas, ao nível de significância de 0,01. Os resultados das diferenças entre as médias das classes foram significativos para $p < 0,01$, indicando assim que existe uma boa separabilidade entre as classes, e o classificador proposto pode ser implementado.

Quadro 1: Valor de F calculados para o teste T^2 de Hotelling para 5 classes presentes nas imagens de raízes de cenoura.

Classe	Fundo_Escuro	Fundo_Claro	Ombro_Roxo	Ombro_Verde
Cenoura	241,1	629,1	52,1	39,9
Fundo_Escuro	-	105,8	309,4	210,3
Fundo_Claro		-	945,3	507,5
Ombro_Roxo			-	34,4

A figura 4 apresenta um gráfico de dispersão da amostra dos pixels utilizados no desenvolvimento do classificador. Nesta figura, podemos verificar visualmente a distinção entre as classes.

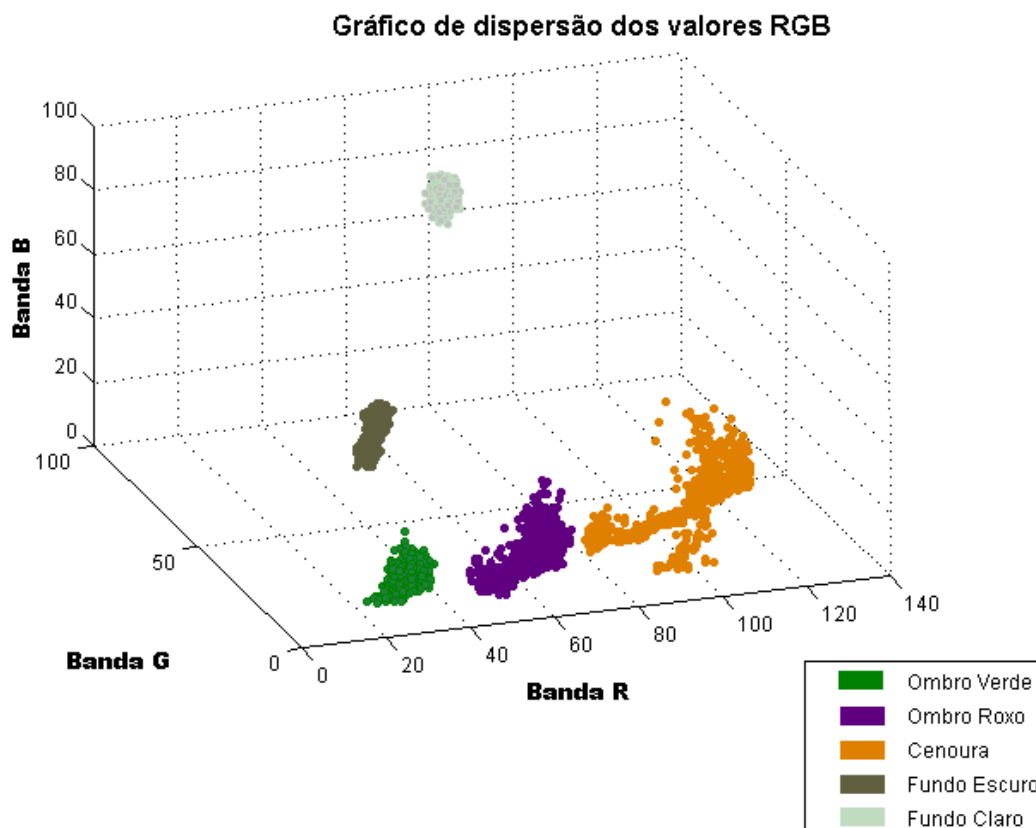


Figura 4. Gráfico de dispersão dos valores RGB das 5 classes implementadas no classificador

Para cálculo dos parâmetros da função discriminante, foi utilizada a rotina PROC DISCRIM do SAS, e o código utilizando os parâmetros definidos por esta rotina foi implementado em linguagem de programação C. Aplicando o vetor de dados de validação ao classificador, o resultado da classificação gerou a matriz de confusão apresentado no Quadro 2.

Quadro 2: Matriz de confusão gerada durante o desenvolvimento da função discriminante.

CLASSE	Cenoura	Fundo claro	Fundo escuro	Ombro Roxo	Ombro Verde
Cenoura	100%	0	0	0	0
Fundo_claro	0	100%	0	0	0
Fundo_escuro	0	0	100%	0	0
Ombro_Roxo	0	0	0	96%	4%
Ombro_Verde	0	0	0	6%	94%

Como a presença de pigmentação é considerada como fator de descarte das raízes, independente da coloração desta, as classes Ombro_Roxo e Ombro_Verde podem ser mescladas, resultando na matriz de confusão do Quadro 3. A figura 5 apresenta o resultado da segmentação de uma raiz com incidência do ombro verde.

Quadro 3: Matriz de confusão gerada durante o desenvolvimento da função discriminante.

CLASSE	Cenoura	Fundo claro	Fundo escuro	Ombro_Roxo/ Verde
Cenoura	100%	0	0	0
Fundo_claro	0	100%	0	0
Fundo_escuro	0	0	100%	0
Ombro_Roxo/Verde	0	0	0	100%



Figura 5. (a) Imagem de uma raiz de cenoura, e (b) imagem segmentada.

Foram realizados testes com 60 imagens, sendo 20 com raízes sem ombro verde, 20 com ombro verde ou roxo incidindo em menos de 10% do comprimento da raiz e o restante com incidência do ombro verde em mais de 10% do comprimento da raiz.

Para validação do sistema, as imagens foram previamente classificadas por um pesquisador da EMBRAPA-Hortaliças, que realiza essa classificação manualmente como rotina de trabalho, e o resultado foi comparado com a classificação das raízes realizada pelo sistema proposto, confirmando que o sistema classificou corretamente todas as imagens, atingindo a exatidão global de 100%.

O Quadro 4 apresenta o tempo de processamento médio obtido para realizar a classificação pixel-a-pixel de uma imagem de raiz de cenoura, utilizando a função discriminante. O acesso aos pixels foi implementado utilizando o método indireto de acesso aos pixels. O tempo de 0,28 s para o processamento de uma imagem de 1280x960 pixels incentivam a implementação de um sistema automático utilizando SVA para a detecção e classificação de raízes de cenoura quanto à incidência de ombro verde ou roxo.

O sistema proposto, implementado em linguagem C, classificou corretamente todas as imagens, atingindo a exatidão global de 100% para as condições controladas de iluminação e aquisição de imagens propostas.

Quadro 4: Tempo médio de processamento da rotina de segmentação e medição do comprimento do ombro verde em uma imagem de uma raiz de cenoura.

Tamanho da imagem em pixels (alt x larg)	Tempo de processamento (s)
960x1280	0,280
331x1061	0,094
331x732	0,047
331x462	0,023

2.4 CONCLUSÕES

O classificador proposto, adotando a análise discriminante utilizando os valores RGB das imagens digitais para segmentar as raízes de cenoura visando a identificação de ombro verde/roxo apresentou resultados satisfatórios, com 100% de acerto na classificação dos pixels das imagens.

O sistema proposto para aceitação ou rejeição das raízes, de acordo com o comprimento da área pigmentada, apresentou a classificação correta de 100% das imagens utilizadas.

A implementação da rotina de classificação em linguagem C, utilizando a biblioteca de software livre OpenCV, apresentou velocidades de processamento máxima de 280ms para processar imagens de 960x1280 pixels e 23ms para processar imagens de 331x362 pixels, incentivando assim o uso desta metodologia para implementação de sistemas automáticos de classificação das raízes quando à incidência ou não de ombro verde/roxo em tempo real, utilizando microcomputadores baseados em arquitetura Intel.

2.5 REFERÊNCIAS BIBLIOGRÁFICAS

BENNEDSEN, B. S.; PETERSON, D. L.; TABB, A. Identifying defects in images of rotating apples **Computers and Electronics in Agriculture**. 48: 92-102. 2005.

BLASCO, J.;ALEIXOS, N.;CUBERO, S.;GÓMEZ-SANCHÍS, J. MOLTÓ, E. **Automatic sorting of satsuma (Citrus unshiu) segments using computer vision and morphological features**. *Computers and Electronics in Agriculture*, v.66, n.1, p.1-8. 2009.

BRADSKI, G; KAEHLER, B. **Learning OpenCV: Computer Vision with the OpenCV** , 1 ed., O'Reilly Media, Inc., 2007, 555 p.

BROSNAN, T.; SUN, D. Inspection and grading of agricultural and food products by computer vision systems-review. **Computers and Electronics in Agriculture**. 36: 193-213. 2002.

COMPANHIA DE ENTREPÓSITOS E ARMAZÉNS GERAIS DE SÃO PAULO - CEAGESP. *Programa brasileiro para a melhoria dos padrões comerciais e embalagens de hortigranjeiros*. Classificação da cenoura. São Paulo: Centro de Qualidade em Horticultura, 1998. 5 p.

FEIPING, N.;SHIMING, X.;YANGQIU, S. CHANGSHUI, Z. **Optimal dimensionality discriminant analysis and its application to image recognition**. *Computer Vision and Pattern Recognition*, 2007. CVPR '07. IEEE Conference on. 17-22 June 2007, 2007. 1-8 p.

FINGER FL; DIAS DCFS; PUIATTI M. 2005. Cultura da cenoura. In: FONTES PCR (ed.). *Olericultura teoria e prática*. Viçosa: Departamento de Fitotecnia/Setor de Olericultura. p.371-384.

GUNASEKARAN, S. Computer vision technology for food quality assurance. **Trends in Food Science e Technology August**. 7: 245-256. 1996

JAHNS, G. A.; MÜLLER, H.; NIELSEN, P. W. Measuring image analysis attributes and modelling fuzzy consumer aspects for tomato quality grading. **Computers and Electronics in Agriculture**. 31: 17-29. 2001.

JOHNSON, R. A.; WICHERN, D. W. R. **Applied multivariate statistica analysis**, 4 ed., Rio de Janeiro: Prentice-Hall, 1998, 816 p.

KONDO, N. *et al.* Machine vision based quality evaluation of lyokan orange fruit using neural network. **Computers and Eletronics in agriculture**. 29: 135-147. 2000.

LANA, M.M.; VIEIRA, J.V. **Fisiologia e Manuseio Pós-Colheita de Cenoura** – 2000, 16 p. Embrapa Hortaliças; Circular Técnica; ISSN 1415-3033;21.

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

LOURO, A. H. F.; MENDONÇA, M. M.; GONZAGA, A. **Classificação de Tomates Utilizando Redes Neurais Artificiais**. In: II Workshop de Visão Computacional - WVC'2006. **Anais...** Escola de Engenharia de São Carlos - São Carlos, v.1. p. 239-244. 2006.

REGAZZI, A. J. **Análise multivariada**, notas de aula INF 766, Viçosa, MG: Universidade Federal de Viçosa, 2000. v.2.

REGUNATHAN, M; LEE, W. S. **Citrus fruit identification and size determnation using machine vision and ultrasonic sensors**. ASAE meeting Presentation, paper number 053017. ASAE annual International Meeting, Florida, USA, 2005.

SIMÕES, A. S.; COSTA, A. H. R. **Classificação de laranjas baseada em padrões visuais**. In: VI Simpósio Brasileiro de Automação Inteligente. Sociedade Brasileira de Automática - SBA. CDROM.14-17 Setembro 2003, p. 77-81.

YANG, Q. **Apple Stem and Calyx Identification with Machine Vision**. Journal of Agricultural Engineering Research, v.63, n.3, p.229-236. 1996.

WATANABE, Y; KOMURO, T; ISHIKAWA, M. **955-Fps Real-Time Shape Measurement of a Moving/Deforming Object Using High-Speed Vision for Numerous-Point Analysis**, 2007 IEEE International Conference on Robotics and Automation (ICRA'07) (Roma, 2007.4.11) / Proceedings, pp. 3192-3197. 2007.

CAPÍTULO 3 CLASSIFICAÇÃO MORFOLÓGICA DE RAÍZES DE CENOURA (*Daucus carota*) UTILIZANDO DESCRITORES TOPOLÓGICOS, ESTATÍSTICOS, DE FOURIER E WAVELETS.

3.1 INTRODUÇÃO

Quando adquire produtos agrícolas no comércio varejista, o consumidor se baseia nas informações visuais, sendo o formato, a textura e ausência de defeitos alguns dos critérios de seleção. No caso de cenouras (*Daucus carota*) o consumidor brasileiro, principalmente dos grandes centros, prefere raízes que apresentam formato cilíndrico, lisas, bem desenvolvidas, ausência de raízes laterais, com diâmetro de 3,5 cm, comprimento de 15-20 cm, coloração alaranjada intensa e sem pigmentação verde ou roxa na parte superior (LANA, 2000).

Na etapa pós-colheita, as raízes de cenoura são selecionadas manualmente, sendo retiradas as raízes quebradas, tortas, pequenas, bifurcadas, rachadas e com outros defeitos mecânicos. Também são eliminadas as raízes com diâmetro menor do que 10 mm e comprimento menor do que 10 cm (IMA, 2002).

A separação e classificação dos produtos podem ser feitas manualmente ou por sistemas automáticos. Os sistemas manuais são tediosos, trabalhosos, inconsistentes e demorados (GUNASEKARAN,1996). Além disto, são subjetivos, pois cada profissional envolvido nos processos pode analisar de forma diferente um mesmo produto, classificando-o em categorias diferentes. Para suprir a subjetividade da operação humana, os sistemas de visão artificial (SVAs) vêm sendo empregados com sucesso na classificação de produtos agrícolas, disponibilizando métodos rápidos, econômicos, consistentes e objetivos, não destrutivos e com acurácia a ser obtida superior à classificação humana (BROSNAN & SUN, 2002).

A classificação de cítricos e maçãs utilizando SVAs têm recebido atenção especial de pesquisadores, como os trabalhos realizados por Simões (2001), Simões (2003) e Kondo (2000). No caso de maçãs, existem trabalhos desenvolvidos por Yang (1996), Bennedsen et al. (2005), Shahin et al. (2001), Leemans & Destain (2004) e Regunathan (2005), com pesquisas realizadas na identificação de defeitos externos, classificação por tipo varietal, separação pela coloração, identificação do cálice e pedúnculo, e em sistemas automáticos de transporte individualizado dos frutos. Na área de olericultura, Janhs et al. (2001) e Louro (2006) apresentaram trabalho sobre separação de tomates utilizando SVAs.

Para a separação de defeitos pelo formato de um objeto qualquer é necessário o levantamento de características (ou descritores) que possam representar a forma, ou a diferença entre formas, dos objetos em estudo. A análise e representação da forma é um dos problemas de maior dificuldade quando se trabalha com sistemas de visão (LARABI, 2009). Os descritores morfológicos a serem extraídas do objeto vão representar sua orientação, ocupação, formato e outras informações que possam melhor descrever este objeto. Estes descritores são normalmente apresentados na forma de vetores do tipo $X=[x_1, x_2, \dots, x_n]$ que serão posteriormente processados por sistemas classificadores. Zhang e Lu (2004) apresentam uma divisão de diversos métodos utilizados para extração de descritores morfológicos de objetos, resumidos na figura 1.

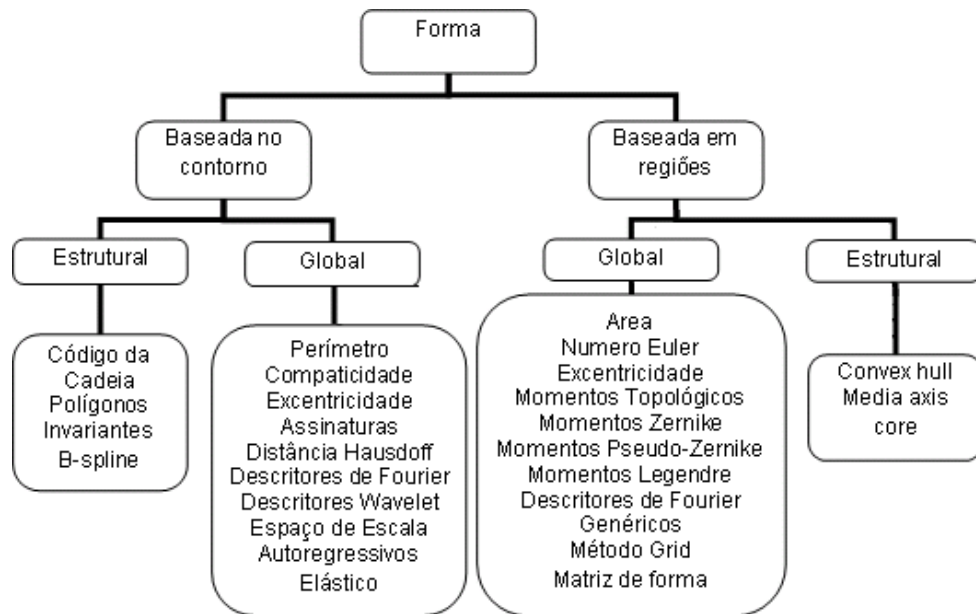


Figura 1. Métodos de extração de descritores para classificação morfométrica (ZANGH & LU, 2004)

Cada um destes descritores ainda pode sofrer alterações de escala, rotação, translação e transformações afins. Dependendo da sua utilização, o conjunto de descritores morfológicos deve ser invariante a estas transformações.

Dentre os descritores utilizados para diferenciar formas, cinco grupos merecem destaque na literatura: os descritores dimensionais ou topológicos, os momentos centrais, os momentos invariantes de Hu e os descritores obtidos pela aplicação das transformadas de Fourier e Wavelet.

Neste trabalho, o objetivo foi calcular os descritores topológicos, os momentos centrais, os momentos invariantes de Hu, os descritores de Fourier e Wavelet obtidos através da assinatura do contorno da imagem da raiz de cenoura, e por meio de estatística multivariada, selecionar os descritores de cada conjunto que melhor discriminam as raízes com formato considerado aceitável para a comercialização. Também foram desenvolvidas e testadas arquiteturas de redes neurais artificiais (RNA's) para discriminar raízes de cenoura quanto ao formato utilizando como entradas as variáveis selecionadas.

3.2 FUNDAMENTAÇÃO TEÓRICA

Descritores topológicos

Os descritores topológicos são compostos por coordenadas de pontos específicos do objeto e por medidas ou relações geométricas da forma obtida, como perímetro, área, diâmetro, relações entre maior e menor eixo, convexidade, e outras medidas específicas para cada aplicação.

Dreyden & Mardia (1998) apresentam uma metodologia de aquisição de coordenadas de pontos em imagens de peixes, e, fixando as coordenadas de um ponto inicial, extraíram distâncias relativas em relação à este ponto. Os autores afirmam que este método resultou na identificação de importantes variações nas formas dos peixes, mas ressaltam que o sucesso do método é dependente do ponto escolhido.

Horgan et al. (2001) utilizaram medidas topológicas para diferenciar cultivares de cenouras quanto ao formato do ápice e do ombro da raiz. O método foi considerado insatisfatório devido às variações do formato que ocorrem dentro de um grupo de raízes pertencentes ao mesmo cultivar. Rashidi & Seyfi (2007) verificaram que medidas da altura, comprimento e largura podem ser utilizadas para classificar melões (*Cucumis melo*) em cinco classes de formatos.

Nagata & Tallada (2008), trabalhando com morangos, definiram cinco eixos paralelos dispostos ao longo do comprimento dos frutos, e usaram as medidas de distância euclidiana entre o ponto médio destes eixos e um ponto no extremo para classificar os frutos em quatro variedades, conforme apresentado na figura 2. Foram utilizadas 546 amostras dos frutos e o vetor resultante foi aplicada a uma rede neural de três camadas, obtendo um resultado de 98% de acertos. Para classificação do comprimento, foi utilizada uma simples regressão entre a área projetada na imagem binária pela massa do fruto, com correlação de 97%.




Figura 2. Descritores utilizados para classificar variedades de morangos (NAGATA & TALLADA, 2008).

Liming e Yanchao (2010) também apresentaram trabalho de classificação de morangos, porém utilizando um equipamento experimental, onde os frutos são dispostos em uma esteira e as imagens adquiridas utilizando uma câmera Panasonic WV-CP470. Com este sistema, obtiveram uma exatidão global próxima de 90% na classificação dos frutos quanto ao formato.

Segundo Loss (2004), em alguns casos os descritores topológicos podem não ser suficientes para discriminar formas, mas podem ser associados a outros descritores para melhoria do processo de discriminação.

Momentos Centrais e Momentos invariantes de Hu

Momentos são valores escalares utilizados para caracterizar uma função e para capturar as suas características, sendo utilizada na mecânica clássica para medir a distribuição de massa de um corpo rígido. Do ponto de vista matemático, os momentos são projeções de uma função em uma base polinomial, similarmente à transformada de Fourier, que é uma projeção sobre uma base de funções harmônicas (FLUSSLER et al., 2009).

A utilização dos momentos de uma imagem é uma forma simplificada de extrair informações estatísticas de objetos presentes em imagens digitais, sendo estas informações utilizadas como descritores para classificação de formas e padrões. Os momentos centrais e os momentos invariantes de Hu extraem informações estatísticas do objeto como um todo e não descrevem pequenos detalhes do formato. Em alguns casos podem ser insuficientes para

classificação de objetos que apresentem grande similaridade no formato, sendo então recomendada sua utilização associada com outros descritores (ZHENG et al., 2006).

Du et al. (2007) utilizaram descritores topológicos associados a momentos invariantes para classificar folhas de diversas plantas utilizando classificadores hiperesféricos com algoritmos de médias móveis (MMC), com resultados de classificação de 93% de acertos. Conci e Monteiro (2004) também utilizaram descritores topológicos associados a momentos invariantes para reconhecimento de placas de veículos, obtendo um resultado de 100% de acertos nos testes realizados.

O cálculo dos momentos parte do princípio de que uma imagem pode ser visualizada como uma função 2D discreta, onde a intensidade de cada pixel é indexada na forma $I(x,y)$, sendo possível extrair os momentos de ordem (p,q) de uma função discreta 2D dada por :

$$M_{pq} = \sum_{x=1}^{largura} \sum_{y=1}^{altura} x^p y^q I(x, y) \quad (1)$$

Em que:

M_{pq} é o momento de ordem p,q

$I(x,y)$ intensidade do pixel de coordenadas (x,y) da imagem I

A partir da equação 1 é possível se obter algumas medidas relacionadas ao objeto de interesse, como o centro de massa (centróide), obtido pelas equações 2 e 3:

$$ct_x = \frac{m_{10}}{m_{00}} \quad (2)$$

$$ct_y = \frac{m_{01}}{m_{00}} \quad (3)$$

Em que:

ct_x, ct_y par coordenado (x,y) do centróide do objeto

m_{01}, m_{10}, m_{00} momentos calculados a partir da equação 1.

Para o caso especial de imagens binárias, onde os pixels com valor unitário pertencem ao objeto e os pixels com valor nulo pertencem ao fundo, o momento m_{00} representa a área do objeto.

Como o cálculo dos momentos é afetado por alterações na escala e rotação da imagem, algumas variações foram sendo desenvolvidos ao longo do tempo, como os momentos centrais e os momentos invariantes de Hu. Os momentos centrais podem ser calculados utilizando a equação 4:

$$\mu_{pq} = \sum_{x=1}^{largura} \sum_{y=1}^{altura} (x - ct_x)^p (y - ct_y)^q I(x, y) \quad (4)$$

Em que:

- μ_{pq} momento central de ordem p,q
- $I(x,y)$ intensidade do pixel de coordenadas (x,y) da imagem I
- ct_x, ct_y par coordenado (x,y) do centroide do objeto

O grupo de sete momentos invariantes definido por Hu (1962) são calculados a partir dos momentos centrais. Estes descritores têm a vantagem de serem invariantes à escala, posição e orientação do objeto, e são obtidos utilizando as equações de 5 a 11.

$$\varphi_1 = \mu_{20} + \mu_{02} \quad (5)$$

$$\phi_2 = (\mu_{20} - \mu_{02})^2 + 4\mu_{11}^2 \quad (6)$$

$$\varphi_3 = (\mu_{30} - 3\mu_{12})^2 + (3\mu_{21} - \mu_{03})^2 \quad (7)$$

$$\varphi_4 = (\mu_{30} + \mu_{12})^2 + (\mu_{21} + \mu_{03})^2 \quad (8)$$

$$\varphi_5 = (\mu_{30} - 3\mu_{12})(\mu_{30} + \mu_{12}) \left[(\mu_{30} + \mu_{12})^2 - 3(\mu_{21} + \mu_{03})^2 \right] + (3\mu_{21} - \mu_{03})(\mu_{21} + \mu_{03}) \quad (9)$$

$$\varphi_6 = (\mu_{20} - \mu_{02}) \left[(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2 \right] + 4\mu_{11}(\mu_{30} + \mu_{12})(\mu_{21} + \mu_{03}) \quad (10)$$

$$\varphi_7 = (3\mu_{21} - \mu_{03})(\mu_{30} + \mu_{12}) \left[(\mu_{30} + \mu_{12})^2 - 3(\mu_{21} + \mu_{03})^2 \right] + (3\mu_{12} - \mu_{30})(\mu_{21} + \mu_{03}) \left[3(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2 \right] \quad (11)$$

Em que:

φ_j é o j-ésimo momento invariante de Hu

μ_{pq} são os momentos centrais obtidos pela equação 4.

Transformada de Fourier

Quando aplicada a sinais variantes no tempo, a transformada de Fourier decompõe o sinal original, resultando em um número de harmônicas que representam as frequências contidas no sinal original (MANZAN, 2006). Uma vantagem adicional na utilização dos descritores de Fourier é que estes podem ser normalizados para serem invariantes quanto à rotação, translação, escala e ainda quanto à escolha do ponto inicial de partida para se levantar o no contorno da imagem (GONZALEZ & WOODS, 2000). No caso de imagens, uma versão dos descritores de Fourier, denominadas de descritores elípticos de Fourier (EFD), vem sendo utilizada para descrição e reconhecimento de formas (TORT, 2003). Estes descritores são obtidos a partir de uma função 1D que represente o formato do objeto, que pode ser o traçado do contorno da imagem do objeto de interesse, gerando assim uma função denominada de função da assinatura.

Esta função da assinatura pode ser uma medida da distância do centróide aos pontos do contorno, uma função da variação do diâmetro ao longo do comprimento ou outra função extraída do formato do objeto, resultando na conversão da imagem $I(x,y)$ em uma função $f(x,y)$ mais simples de ser descrita. A partir desta função $f(x,y)$, pode-se obter transformações para extrair outros descritores de forma, como os obtidos pela aplicação das transformadas de Fourier e Wavelet.

A figura 3 apresenta a função de assinatura $r(\theta)$ obtida variando-se o ângulo θ e calculando-se a distância do centróide ao ponto pertencente ao contorno do objeto (GONZALEZ & WOODS, 2000).




Figura 3. Exemplo do gráfico de assinatura do contorno de uma imagem (GONZALEZ & WOODS, 2000)

A função de assinatura \hat{b} pode ser obtida através das coordenadas de cada pixel pertencente ao contorno, $x(k)=x_k$ e $y(k)=y_k$, e das coordenadas do centróide da imagem, c_x e c_y , tratada como um número complexo da forma apresentada na equação 12.

$$\hat{b}(k) = (x_k - c_x) + j(y_k - c_y) \quad (12)$$

para $k=0,1,\dots,N-1$, em que N é o número de pixels pertencentes ao contorno da imagem.

O contorno pode então ser descrito como um conjunto de harmônicas, caracterizadas geometricamente como elipses, em que cada harmônica é definida por quatro coeficientes denominados de descritores de Fourier elípticos (EFD) (NASREDDINE et al.,2009). O formato de um objeto é então convertido a uma função, que por sua vez pode ser decomposta em uma soma de coeficientes que descrevem esta elipse, sendo que a k -ésima harmônica é formada pelos coeficientes calculados através das equações de 13 a 16.

$$a_k = \frac{1}{2k^2\pi^2} \sum_{i=1}^N \frac{\Delta x_i}{\Delta s_i} \left[\cos\left(\frac{2k\pi s_i}{L}\right) - \cos\left(\frac{2k\pi s_{i-1}}{L}\right) \right] \quad (13)$$

$$b_k = \frac{1}{2k^2\pi^2} \sum_{i=1}^N \frac{\Delta x_i}{\Delta s_i} \left[\sin\left(\frac{2k\pi s_i}{L}\right) - \sin\left(\frac{2k\pi s_{i-1}}{L}\right) \right] \quad (14)$$

$$c_k = \frac{1}{2k^2\pi^2} \sum_{i=1}^N \frac{\Delta y_i}{\Delta s_i} \left[\cos\left(\frac{2k\pi s_i}{L}\right) - \cos\left(\frac{2k\pi s_{i-1}}{L}\right) \right] \quad (15)$$

$$d_k = \frac{1}{2k^2\pi^2} \sum_{i=1}^N \frac{\Delta y_i}{\Delta s_i} \left[\sin\left(\frac{2k\pi s_i}{L}\right) - \sin\left(\frac{2k\pi s_{i-1}}{L}\right) \right] \quad (16)$$

Em que:

- L é a curvatura do contorno do perímetro;
- s_i é a abscissa curvilínea do ponto i ;
- Δx_i é a diferença entre as abscissas x_i e x_{i-1} ;
- Δy_i é a diferença entre as ordenadas y_i e y_{i-1} ;
- Δs_i é o desvio padrão de Δx_i e Δy_i ;
- k é a k-ésima harmônica
- a_k, b_k, c_k, d_k coeficientes da k-ésima harmônica

A magnitude da harmônica é calculada utilizando a equação 17.

$$Mag_k = \frac{1}{2} \sqrt{a_k^2 + b_k^2 + c_k^2 + d_k^2} \quad (17)$$

Os valores Mag_k , para $(k=0, 1, \dots, N-1)$ na equação 17, normalizada pela magnitude do primeiro coeficiente Mag_0 , é utilizada como descritor de forma. Os valores adquiridos são invariantes a translação, escala e rotação, o que é muito favorável para uma boa representação de formas (ZHANG & LU, 2004).

Ghazanfari et al. (1997) utilizaram os descritores de Fourier para classificar 120 pistaches em 4 classes, utilizando as primeiras 15 harmônicas

obtidas das imagens binarizadas. Este vetor foi aplicado a uma rede neural artificial do tipo perceptron multicamadas com 15 entradas, 5 unidades de processamento na camada intermediária e 4 na camada de saída, com resultados de classificação de 98,5% para pistaches com casca e 92,3% para pistaches sem casca.

Menesatti et al. (2008) utilizaram descritores de Fourier e análise multivariada para classificar quatro variedades de avelãs, sendo duas variedades de formato alongado e duas de formato arredondado. Foram utilizadas as primeiras 16 harmônicas, e o resultado da classificação entre o formato alongado e arredondado foi superior a 95% e entre as variedades foi de 98,8% quando utilizada a imagem adquirida da parte lateral da avelã.

Nasreddine et al. (2009) descrevem que o reconhecimento de formar utilizando os descritores de Fourier é o método mais utilizado para caracterizar e classificar estruturas calcificadas. Aplicando a transformada de Fourier em imagens obtidas de conchas marinhas, os autores obtiveram 68,55% de acertos na classificação quanto ao formato, utilizando apenas as primeiras oito harmônicas.

Os primeiros termos da série de Fourier capturam informações da forma global do objeto, enquanto os últimos capturam os detalhes mais finos. Uma deficiência da transformada de Fourier aplicada ao contorno ou à assinatura do contorno é que não captura informações do interior das imagens, o que é muito importante para discriminação de algumas formas. Zhang & Lu (2004) sugerem que ao utilizar os descritores de Fourier, deve-se utilizar pelo menos as 20 primeiras harmônicas, ou utilizar uma rotina de análise discriminante passo-a-passo para seleção das harmônicas que melhor diferenciam o formato.

Transformada Wavelet

Da mesma forma que a transformada de Fourier, a transformada Wavelet permite a decomposição do sinal $f(x,y)$ em valores que representam a participação de cada frequência no sinal original, porém com a vantagem de informar também em que ponto do sinal ocorre esta participação.

A transformada Wavelet é formada por um conjunto de funções base $\psi \in L^2(\mathbb{R})$ com média zero, como a de Meyer, Haar, Morlet e outras, que são aplicadas à função original. Uma das funções base é escolhida, e é feita a convolução desta com o sinal original, obtendo-se a covariância entre os dois sinais. Depois, a função base é alterada na escala do tempo, e novamente é feita a convolução. Este processo é repetido k vezes, com $k=1,2,4,8,16\dots$, onde k é o fator de escala que altera a escala do tempo da função base. A figura 4 ilustra esse processo.




Figura 4. (a) Correlação da wavelet mãe $\psi(t)$ com o sinal $s(t)$; em (b), a wavelet $\psi(t)$ é deslocada para a direita e calculada nova correlação, e em (c) wavelet $\psi(t)$ é dilatada para um novo fator de escala e novamente aplicado ao sinal original. (Mathworks, 2009)

A transformada Wavelet é definida como $\psi(t)$, apresentada na equação 18.

$$Wf(u, s) = \langle f, \psi_{u,s} \rangle = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{|s|}} \psi^* \left(\frac{t-u}{s} \right) dt \quad (18)$$

Em que:

* indica o conjugado complexo.

s parâmetro de translação e indica o deslocamento s da função $\psi(t)$ no eixo t.

u parâmetro de escala, alterando a escala da função $\psi(t)$.

Se $\psi_{u,s}(t)$ for definida como na equação 19, a transformada Wavelet pode ser reescrita como o produto interno das funções $f(t)$ e $\psi_{u,s}(t)$, apresentado na equação 20:

$$\psi_{u,s}(t) = \frac{1}{\sqrt{|s|}} \psi\left(\frac{t-u}{s}\right) \quad (19)$$

$$Wf(u, s) = \langle f(t), \psi_{u,s}(t) \rangle = \int_{-\infty}^{+\infty} f(t) \psi_{u,s} dt \quad (20)$$

A função resultante Wf é um descritor de forma que é invariante à rotação, translação, escala e independente se o objeto é convexo ou não (KONG et al., 2007).

A função $\psi_{1,0}(t)$ é chamada de wavelet mãe, enquanto que funções $\psi_{u,s}(t)$ para $u \neq 1$ e $s \neq 0$ são chamadas de wavelets filhas. Dentre as funções $\psi(t)$ utilizadas, a mais conhecida é a de Haar, definida pela equação 21:

$$\psi(t) = \begin{cases} 1 & , \quad \text{se } 0 \leq t \leq \frac{1}{2} \\ -1 & , \quad \text{se } \frac{1}{2} \leq t \leq 1 \\ 0 & , \quad \text{caso contrário} \end{cases} \quad (21)$$

A figura 5 apresenta a função de Haar original $\psi_{1,0}(t)$, e a função de Haar deslocada no eixo t, $\psi_{1,1}(t)$.



Figura 5. Gráfico das funções de Haar original $\psi_{1,0}(t)$ (a) e deslocada no eixo t , $\psi_{1,1}(t)$ (b)

Kong et al. (2007) utilizaram a assinatura obtida a partir das distâncias do centróide ao contorno nas imagens tomadas de 1100 peixes, e a partir dos 16 primeiros coeficientes obtidos pela aplicação da transformada Wavelet, obtiveram resultados de classificação superiores aos obtidos utilizando os momentos topológicos. Loss (2004) utilizou a transformada Wavelet com as funções base de Coiflet e Daubechies para classificar corretamente 20 espécies de folhas.

3.3 MATERIAL E MÉTODOS

A primeira parte da pesquisa foi realizada no Embrapa Hortaliças, em Brasília-DF. Um total de 270 amostras foi utilizado, sendo 165 cenouras com formato aceitável e 105 com alguma deformação no formato. Para aquisição das imagens, foi utilizada uma câmera DBK41B, da The Imaging Source, com interface USB, e o software de captura IC Capture. As cenouras foram colocadas em uma câmara de iluminação controlada para aquisição de imagens, construída em madeira, com dimensões de 130x100x80 cm, forrada internamente com fórmica cinza fosca. O sistema de iluminação foi composto de seis lâmpadas fluorescentes PHILIPS de uso comum, de 40 watts cada. As lâmpadas foram dispostas perpendicularmente ao plano de aquisição de imagens. As imagens são formadas por 1280x960 pixels, nos valores RGB, com resolução espacial de 10x10 mm.

As imagens obtidas foram processadas no Laboratório PROVISAGRO, da Universidade Federal de Viçosa, Viçosa-MG. Para processamento das imagens e cálculo dos descritores, foi desenvolvido um programa em

linguagem C, o Classifica, utilizando a biblioteca de software livre OpenCV. O programa Classifica lê uma imagem RGB, realiza o processamento das imagens, calcula as coordenadas de contorno da imagem e calcula os descritores topológicos e os momentos.

Após esta etapa, os descritores foram divididos nos cinco grupos propostos (topológicos, momentos, momentos invariantes, descritores de Fourier e descritores de wavelet). Em cada um dos grupos foi realizado o descarte de descritores, visando a redução da dimensionalidade dos conjuntos de descritores e selecionando, em cada um dos conjuntos, os que melhor discriminam as classes.

Para realizar o descarte de descritores, foi utilizado o método passo-a-passo, realizado através do procedimento STEPDISC do SAS (SAS, 2004). O algoritmo inicia com um modelo sem nenhum descritor, e são escolhidos os descritores que sairão ou permanecerão de acordo com o critério Wilks' lambda.

A cada passo, o modelo é examinado. Se o descritor que menos contribui para o poder discriminatório do modelo falha no critério de Wilks' lambda, ele é então removido. Da mesma forma, se o descritor que está inicialmente fora do modelo passa pelo critério de Wilks' lambda, ele é inserido no modelo. O processo termina quando todas os descritores foram selecionados (SAS, 2008).

Processamento das imagens

Após a aquisição da imagem, esta foi limiarizada para separar o objeto do fundo. Para realizar a limiarização, foi utilizado o algoritmo proposto por Otsu (1979), que utiliza o histograma para identificar duas classes (objeto e fundo). Para diminuir o tempo computacional nos cálculos realizados na etapa de limiarização da imagem, foi inicialmente obtido o histograma da imagem monocromática a partir da conversão da imagem RGB original, e das bandas R. A imagem original foi também convertida para o espaço HSV e verificado o histograma da banda S.

Após a limiarização, a imagem foi recortada para o menor retângulo circunscrito à imagem original, chamado de retângulo básico. Depois foram realizadas operações morfológicas de dilatação e erosão para eliminação de ruídos resultantes do processo de limiarização. As raízes que apresentaram um retângulo com comprimento menor do que 10 cm e diâmetro menor do que 1 cm foram descartadas.

Para cada imagem foram extraídos os descritores, sendo o Grupo 1 composto pelos descritores topológicos, o Grupo 2 composto pelos momentos centrais, o Grupo 3 pelos momentos invariantes de Hu, o Grupo 4 contendo os 16 descritores de Wavelet utilizando como função base a função de Haar e o Grupo 5 contendo as 16 primeiras harmônicas obtidas pela transformada de Fourier. Os valores destes descritores foram normalizados para média zero e variância unitária.

Para cada grupo de descritores foi utilizada a análise discriminante passo-a-passo, para selecionar o conjunto de descritores que melhor discriminam as classes. Este processo é apresentado na figura 6.

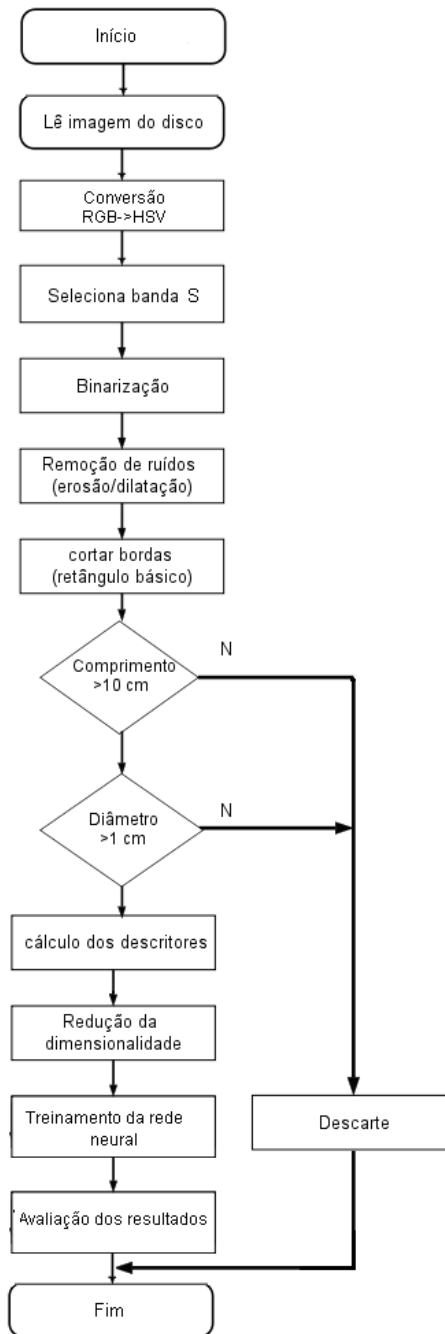


Figura 6. Diagrama da metodologia utilizada para obtenção dos descritores de formato

Os descritores selecionados foram aplicados a classificadores baseados em redes neurais alimentadas adiante de duas camadas, com uma camada intermediária e uma camada de saída.

Cálculo dos descritores geométricos

Para extração das características geométricas, foram traçadas linhas perpendiculares representando o diâmetro de cada segmento do objeto,

distanciadas de 50 pixels cada. A partir da metade de cada linha desta, foi traçada um segmento de reta ligando dois diâmetros consecutivos. Foram calculados a distância euclidiana entre os pontos médios dos diâmetros consecutivos (c_D), o somatório destas distâncias (c_{TS}) e um comprimento linear (c_T), que é a distância entre o primeiro e último diâmetro. Ainda baseado nestes segmentos, foram calculados os ângulos de inclinação de cada segmento de reta (θ_R), e o somatório de todos estes ângulos (θ_T). Também foram obtidos a altura (Alt) e o comprimento (Comp) do objeto, o centro (c_x, c_y) e o centróide (ct_x, ct_y). A figura 7 apresenta uma imagem limiarizada de uma raiz de cenoura, com os diâmetros traçados, o centro, o centróide, os segmentos de reta c_D que interligam os pontos médios dos diâmetros e o comprimento linear. A figura 8 apresenta um recorte da figura 6, destacando um segmento de reta C_D e o ângulo θ_R .




Figura 7. Exemplo do traçado dos diâmetros, do segmento de reta interligando o ponto médio destes segmentos (c_D), das coordenadas do centro e do centróide, e comprimento linear (c_T) entre o primeiro e último diâmetro




Figura 8. Detalhamento de um segmento de reta C_D que interliga dois diâmetros consecutivos e o ângulo de inclinação θ_R deste segmento

Foram selecionados o maior ângulo interno (θ_{Rmax}), o maior eixo vertical interno (c_{Dmax}) e o perímetro (P) do contorno, e calculada a distância absoluta

entre o centro e o centróide no eixo x (d_{cc}), a distância euclidiana entre o centro e o centróide ($d_{e_{cc}}$). Além destes, foram calculados ainda a área relativa, que é a relação entre a área do objeto e a área do retângulo básico, obtida pela equação 22.

$$A_e = \frac{A_T}{A_I} \quad (22)$$

Em que:

- A_e área efetiva de um objeto
- A_T área do retângulo circunscrito no objeto
- A_I é a área do objeto

A circularidade é um descritor que define se o objeto se aproxima de uma forma circular, dada pela equação 23:

$$\varepsilon = \frac{4\pi A_T}{P^2} \quad (23)$$

Em que:

- ε índice que representa a circularidade de um objeto
- A_T área do retângulo circunscrito no objeto
- P perímetro do objeto

A conicidade define se a forma do objeto se aproxima de um formato triangular ou retangular, dada pela equação 24.

$$C = \frac{ct_x}{c_x} \quad (24)$$

Em que:

- C índice que representa se o objeto tem forma próxima a um triângulo;

ct_x coordenada da abcissa do centróide do objeto
 c_x coordenada da abcissa do centro do objeto

Outro descritor de forma utilizado foi a relação entre a medida do segundo e o (n_e-2) diâmetros, onde n_e é o numero de eixos verticais tomados ao longo do comprimento, dado pela equação 25:

$$Ror = \frac{C_{D2}}{C_{D(n_e-2)}} \quad (25)$$

Em que:

Ror Relação entre diâmetros tomados ao longo do objeto.
 C_{D2} segundo diâmetro tomado a partir do ápice da raiz.
 $C_{D(n_e-2)}$ é o n-ésimo diâmetro tomado a partir do ápice da raiz.

O último descritor de forma utilizado foi a variância das diferenças das medidas tomadas entre a borda da imagem e o contorno do objeto, que é uma medida de erro entre o formato do objeto e do retângulo circunscrito a ele. A figura 9 apresenta a extração das distâncias e as equações 26 e 27 apresentam o cálculo da diferença das distâncias entre o objeto e a borda da imagem e o calculo da variância destas diferenças (var_{convex}) :




Figura 9. Detalhamento das medidas de distância entre o objeto e a borda da imagem.

$$dif(k) = |dc_k - db_k| \quad (26)$$

$$\text{var}_{convex} = \sum_{k=1}^n \left(dif_k - \overline{dif} \right)^2 \quad (27)$$

Em que:

dc_k e db_k são as k-ésimas distâncias tomadas da borda do objeto até o retângulo circunscrito.

var_{convex} variância das distâncias tomadas da borda do objeto ao retângulo circunscrito

Cálculo dos momentos centrais, momentos invariantes de Hu, descritores de Fourier e descritores wavelet

A extração dos momentos centrais e dos momentos invariantes foi executada a partir da imagem binária, de acordo com o descrito anteriormente.

Para extração dos descritores de Fourier e Wavelet, primeiramente foi aplicada a função `cvFindContours` contida na biblioteca `OpenCv` para encontrar o contorno da imagem, e depois calculada a distância euclidiana do centróide do objeto a cada ponto do contorno, resultando na função de assinatura do contorno. As transformadas de Fourier e Wavelet da função de assinatura foram obtidas através do pacote computacional `MATLAB`, resultando em 16 descritores de Fourier e 16 descritores de Wavelet.

Classificação da forma utilizando Redes Neurais Artificiais

Para realizar a classificação, foi adotada uma rede neural alimentada adiante de duas camadas, com função de saída sigmoideal. O número de conexões da camada de entrada variou de acordo com o número de descritores aplicados à rede. A camada de saída é composta de dois neurônios, representando as classes “Aceitável” e “Rejeitada”, e a camada intermediária variando de 2 a 20 neurônios.

Na validação da rede foi utilizada a técnica de validação cruzada múltipla, dividindo-se a amostra de dados em K conjuntos, para K=10. O modelo é treinado com todos os subconjuntos, exceto um, e o erro de validação é medido testando-o com o subconjunto deixado de fora do

treinamento. Desta forma, o desempenho da generalização da rede é medido sobre o conjunto de teste, que é diferente do subconjunto de validação (HAYKIN, 2001). A figura 10 ilustra este modelo para $K=4$.




Figura 10. Ilustração do método de validação cruzada múltipla, para $K=4$. Para cada etapa de treinamento, o subconjunto sombreado é deixado de fora para validação do modelo (HAYKIN, 2001)

Para evitar o ajustamento excessivo dos dados durante o treinamento da rede, o que prejudica a capacidade de generalização da rede, foi utilizada a técnica de ‘parada mais cedo’. Esta técnica divide a amostra de treinamento em duas, uma para treinamento e outra para teste. A parte de teste é utilizada para interromper a atualização dos parâmetros livres, evitando a ‘memorização’ da rede. A parada ocorre quando se detecta um aumento do EQM na amostra utilizada para interromper o treinamento (HAYKIN, 2001).

Para avaliação do desempenho dos classificadores, foi adotada a matriz de confusão e calculado o coeficiente kappa (CONGALTON, 1991).

3.4 RESULTADOS E DISCUSSÃO

O software Classifica foi executado em plataforma IBM-PC, com processador Intel Duo-Core E2180 2GHz, com 2 Gb de memória RAM, executando as operações de leitura das imagens armazenadas em disco, processamento das imagens e cálculo dos descritores. Para o processamento de 270 imagens, o software consumiu 97 segundos, com um tempo médio de processamento de 0,36 segundos por imagem.

Para realizar a limiarização das imagens, foi inicialmente obtido o histograma da banda R da imagem RGB original, e o histograma da imagem monocromática a partir da conversão da imagem RGB original. A imagem original foi também convertida para o espaço HSV, sendo então verificado o histograma da banda S. As imagens obtidas e o histograma de cada imagem são apresentados na figura 11.

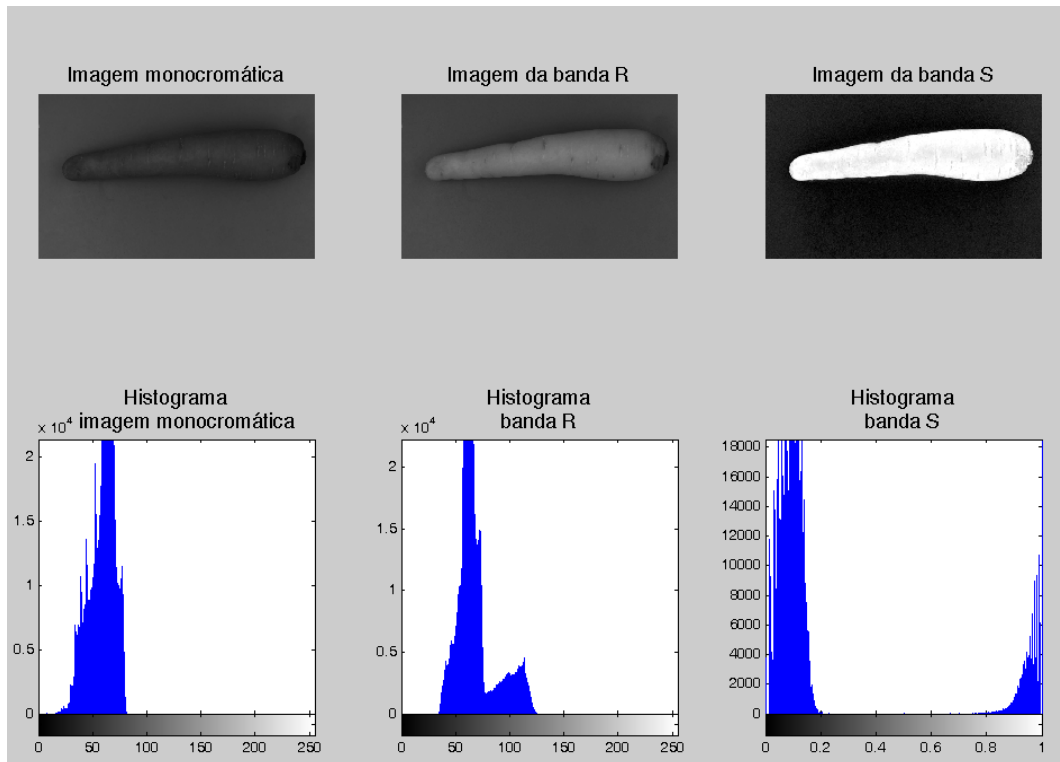


Figura 11. Histograma obtido de uma imagem monocromática, da banda R e da banda S

Pela análise dos histogramas, a banda S da imagem HSV foi selecionada para ser limiarizada, pois apresenta uma maior separação entre as classes fundo e objeto.

A figura 12 apresenta o resultado da limiarização da imagem e da extração dos descritores topológicos. São apresentadas duas imagens, uma com formato aceitável e outra com formato rejeitado.

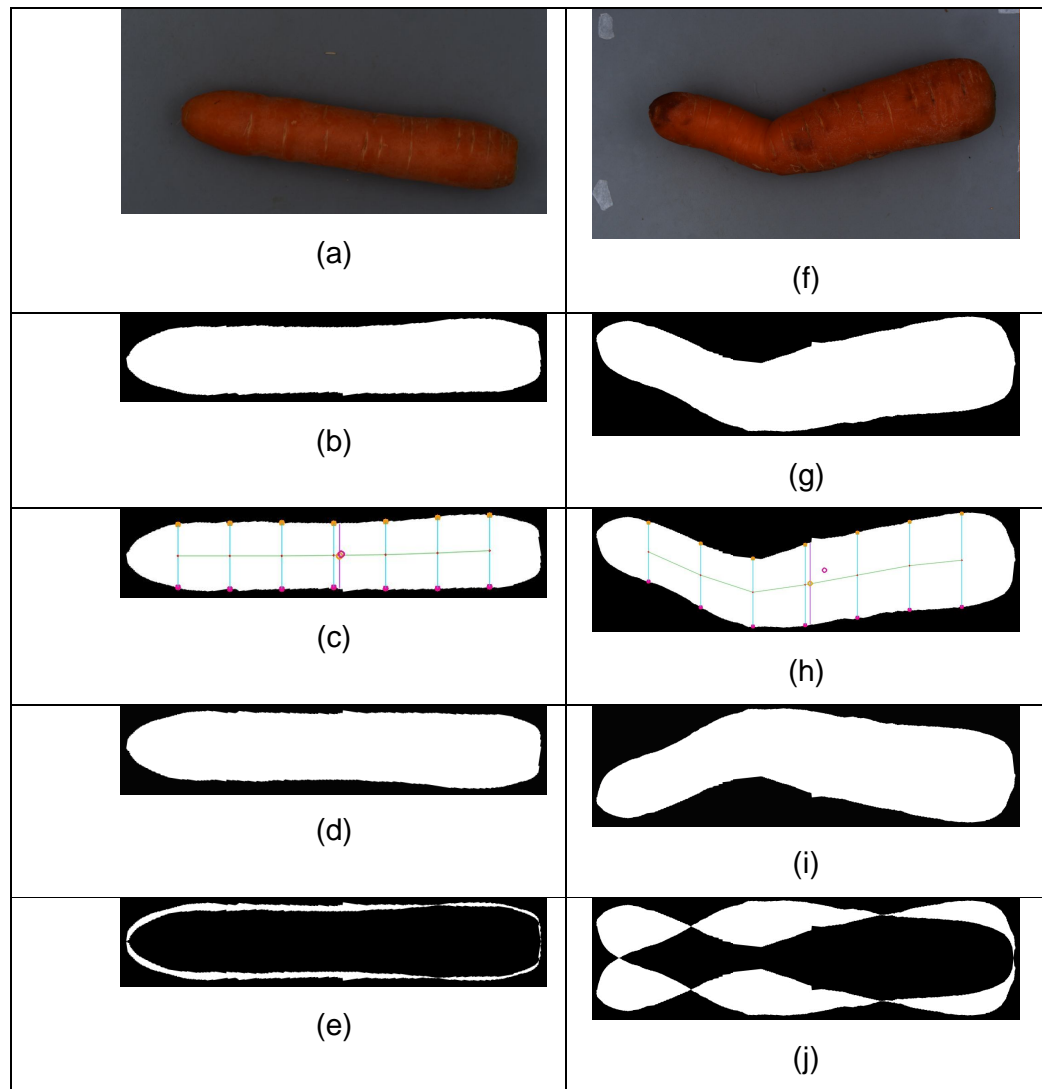


Figura 12. Sequência de extração dos descritores topológicos: Imagem original (a) e (f); resultado da limiarização (b) e (g); extração dos pontos de controle (c) e (h); imagem refletida (d) e (i); (e) resultado da operação Xor entre as imagens (b) e (d); (J) resultado da operação Xor entre as imagens (g) e (i);

A figura 13 apresenta a assinatura do contorno de uma raiz com formato aceitável, e a figura 14 uma com formato rejeitado. As assinaturas foram obtidas calculando-se a distância do centro da imagem aos pontos de contorno. Na figura 14 pode-se perceber a assimetria do formato do sinal.

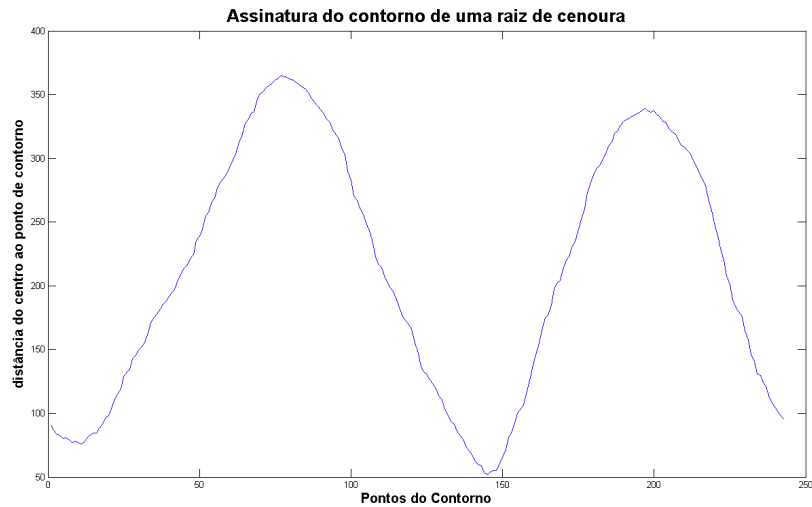


Figura 13. Assinatura do contorno de uma raiz de cenoura com formato aceitável.

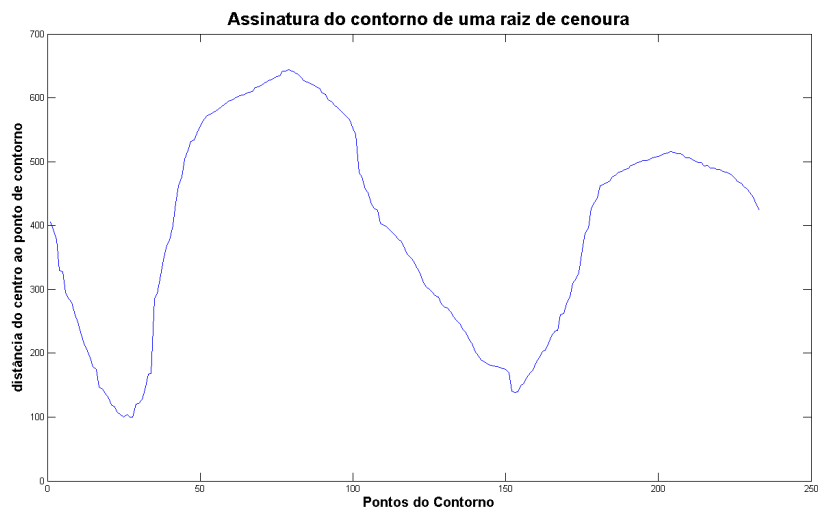


Figura 14. Assinatura do contorno de uma raiz de cenoura com formato rejeitado.

A matriz dos descritores topológicos foi aplicada à rotina STEPDISC do SAS, obtendo o resultado apresentado no Quadro 1.

Quadro 1: Sumário do resultado da rotina STEPDISC para seleção de descritores .

Passo	Variável incluída	F
1	maiorangulo	264,93
2	distcc	55,03
3	Varconvex	6,83
4	media_angulos	11,02

As variáveis selecionadas foram o maior ângulo interno (θ_{Rmax}), a distância euclidiana entre o centro e o centróide ($dist_{cc}$), a variância das diferenças das medidas tomadas entre a borda da imagem e o contorno do objeto (var_{convex}) e a média do somatório dos ângulos dos segmentos internos ($\theta_{RTmédio}$).

Este vetor foi aplicado a uma rede neural alimentada adiante de duas camadas, com quatro entradas, a camada intermediária variando de 2 a 20 neurônios e dois neurônios na camada de saída. A amostra foi dividida em 10 subconjuntos e o treinamento foi efetuado utilizando a validação cruzada múltipla, sendo o treinamento feito com 9 subconjuntos e a validação com o subconjunto resultante. A amostra de treinamento foi ainda dividida em 85% para treinamento e 15% para teste. O Quadro 2 apresenta os valores de kappa e da exatidão global para as arquiteturas de rede que apresentaram valores de kappa maior do que 70%.

Quadro 2: Valores de exatidão global e coeficiente kappa para diferentes números de camadas intermediárias das redes neurais avaliadas.

Numero Neurônios na camada intermediária	Exatidão global	Coeficiente kappa
15	90,9%	73,0% a
22	90,9%	73,0% a
8	90,2%	73,0% a
9	90,2%	73,0% a
19	90,2%	71,8% a
25	90,2%	71,8% a
13	90,2%	71,7% a
20	90,2%	71,1% a
6	90,2%	70,4% a

Coeficientes kappa global seguidos de mesma letra não diferem entre si pelo teste Z, ao nível de 5%

Como os classificadores não diferem entre si pelo teste Z ao nível de 5%, foi selecionada a arquitetura com o menor número de neurônios na camada intermediária, pois segundo Khoury Junior (2004), arquiteturas mais simples possuem maior capacidade de generalização e demandam menor custo computacional.

A exatidão global da rede selecionada foi de 90,2%, para um coeficiente kappa de 70,4%, o que indica em uma classificação considerada muito boa. A diferença da magnitude entre os dois valores é que a exatidão global leva em conta somente os valores de concordância, dispostos na diagonal da matriz de confusão, enquanto o coeficiente kappa inclui também no seu cálculo os outros valores da matriz de confusão, chamados de valores de discordância (CONGALTON, 1991), subestimando a classificação.

Comparando como o trabalho de Liming e Yanchao (2010), pode-se então concluir que os valores dos descritores topológicos obtidos neste trabalho são satisfatórios para identificar cenouras com formato aceitável para comercialização. Estes autores obtiveram um tempo de processamento de 3 s por imagem, representando um custo computacional acima do atingido por este trabalho.

O mesmo procedimento foi realizado para os grupos de variáveis 2,3, 4 e 5. No Quadro 3 são apresentadas as variáveis selecionadas para cada grupo, a precisão da classificação obtida e o coeficiente kappa de cada grupo.

Quadro 3: Resultado da classificação global, coeficiente kappa e arquitetura da rede neural para cada grupo de descritor

Numero	Grupo de descritores	Descritores selecionados	Num. de neurônios	Exatidão global	Coeficiente kappa
1	Topológicos	θ_Rmax $dist_{cc}$ var_{convex} $\theta_{RTmédio}$	6	93,3%	86,1%
2	Momentos	m_{00} m_{10} μ_{20}	6	77,7%	7,0%
3	Momentos invariantes de HU	Hu_3 Hu_5	8	76,2%	8,62%
4	Descritores de Fourier	F_2 F_{16}	14	72,2%	38,7%
5	Descritores de Haar.	$Haar_2$ $Haar_6$ $Haar_7$ $Haar_8$	6	68,0%	14,5%

Verificando o Quadro 3, observa-se que os grupos de descritores de 2 a 5 não foram satisfatórios para identificar pequenas diferenças no formato.

No caso dos momentos e dos momentos de Hu, o baixo valor do coeficiente kappa quando comparado com a precisão global se deve ao fato de que modelo não identificou raízes defeituosas, classificando assim a maioria das raízes como sendo com formato aceitável.

Desta forma, pode-se concluir que a utilização dos momentos não contribui para a identificação de raízes com formato não aceitável. A utilização dos momentos é recomendada para diferenciação entre formas que apresentem acentuadas diferenças, como o proposto por Du et al. (2007), que

utilizaram os momentos invariantes para identificar folhas de 20 espécies de plantas.

A aplicação de transformadas espectrais de Fourier e Wavelet na assinatura do contorno das imagens também não apresentou resultados satisfatórios, pois são mais indicadas para detectar reentrâncias que provoquem inclusões de harmônicas na assinatura do contorno, como em Kondo (2007). Neste trabalho, o autor afirma que a transformada Wavelet conjugada com a assinatura do contorno de imagens de pescado apresenta bons resultados no que diz respeito à invariância à rotação, escala e translação, mas deve ser preferencialmente combinado com outros descritores para melhor identificação de formas.

Também em Chen (2000), verifica-se a habilidade das transformadas de Fourier e Wavelet identificarem uma forma quando esta sofre rotação. Uma outra aplicação é no reconhecimento de formas semelhantes, como em Zhang e Lu (2002), onde foram utilizadas para a recuperação de imagens semelhantes em bancos de dados.

3.5 CONCLUSÕES

O primeiro grupo de descritores, formado por medidas topológicas, compostas pelas medidas geométricas, coordenadas de pontos específicos do objeto e de relações entre estas medidas apresentou melhores resultado na classificação, atingindo uma exatidão global de 93,3% e um coeficiente kappa de 86,1%.

O segundo e terceiro grupo utilizam a teoria clássica dos momentos, divididos em momentos, momentos centrais e momentos invariantes apresentaram valores de kappa próximos de zero, sendo considerados como efetuando uma classificação aleatória.

O quarto e quinto grupo são formados pelas transformadas de Fourier e Wavelet, que são teorias originalmente associadas ao processamento de sinais. Estes dois grupos também apresentaram baixos valores de kappa, com

38,7% para a classificação utilizando a transformada de Fourier e 14,5% utilizando os descritores wavelet utilizando a função de Haar.

3.6 REFERÊNCIAS BIBLIOGRÁFICAS

BENNEDSEN, B.S; PETERSON, D.L.; TABB, A. **Identifying defects in images of rotating apples**. Computers and Electronics in Agriculture. 48: 92-102. 2005.

BROSNAN, Tadhg; SUN, Da-Wen. Inspection and grading of agricultural and food products by computer vision systems-review. **Computers and Electronics in Agriculture**. 36: 193-213. 2002.

CHEN, C.-S.;YEH, C.-W. YIN, P.-Y. **A novel Fourier descriptor based image alignment algorithm for automatic optical inspection**. Journal of Visual Communication and Image Representation, v.20, n.3, p.178-189. 2009.

CONCI, A. ; MONTEIRO, L. H. . **Reconhecimento de placas de veículos por imagem**. In: III Congresso Nacional de Engenharia, 2004. III Congresso Nacional de Engenharia CONEM.

CONGALTON, R. G. **A review of assessing the accuracy of classifications of remotely sensed data**. Remote Sensing of Environment, v.37, n.1, p.35-46, 1991.

DRYDEN, I. L; MARDIA, K. V.Shape Analysis .John Wiley & Sons Ltd. 376 p. 1998. Inglaterra.

DU, J.-X.;WANG, X.-F. ZHANG, G.-J. **Leaf shape based plant species recognition**. Applied Mathematics and Computation, v.185, n.2, p.883-893. 2007.

FLUSSER, J; SUK, T; ZITOVÀ, B. **Moments and Moment Invariants in Pattern Recognition**. Chippenham, UK: John Wiley & Sons. 2009, 303 p.

GHAZANFARI, A.;IRUDAYARAJ, J.;KUSALIK, A. ROMANIUK, M. **Machine Vision Grading of Pistachio Nuts Using Fourier Descriptors**. Journal of Agricultural Engineering Research, v.68, n.3, p.247-252. 1997.

GONZALEZ, R.C.; WOODS, R.E. **Processamento de imagens digitais**. São Paulo: Editora Edgard Blücher Ltda, 2000. 509p.

GUNASEKARAN, Sundaram. Computer vision technology for food quality assurance. **Trends in Food Science & Technology August**. 7: 245-256. 1996.

KOURY JUNIOR, J. K. **Desenvolvimento de um sistema de visão artificial para classificação de madeira serrada de eucalipto**. Viçosa: UFV, 2004. 101 p. Tese (Doutorado) – Departamento de Engenharia Elétrica, UFV, Viçosa, 2004.

HAYKIN, S.; *Redes Neurais: Princípios e Prática*. Tradução: Engel, P.M.; Bookman, 2ª Ed.; Porto Alegre, 2001.

HORGAN, G. W.; TALBOT, M. DAVEY, J. C. Use of statistical image analysis to discriminate carrot cultivars. *Computers and Electronics in Agriculture*, v.31, n.2, p.191-199. 2001.

HU, MI. **Visual pattern recognition by moment invariants**. *Information Theory, IRE Transactions on*, v.8, n.2, p.179-187. 1962.

IMA. PORTARIA Nº 488, DE 5 DE FEVEREIRO DE 2002. Estabelece padrões para cenoura destinada a certificação de origem e qualidade.

JAHNS, Gerhard A.; MØLLER, Henrik; NIELSEN, Paul Wolfgang. Measuring image analysis attributes and modelling fuzzy consumer aspects for tomato quality grading. **Computers and Electronics in Agriculture**. 31: 17-29. 2001.

KONDO, N.; AHMAD, U.; MONTA, M. MURASE, H. **Machine vision based quality evaluation of lyokan orange fruit using neural networks**. *Computers and Electronics in Agriculture*, v.29, n.1-2, p.135-147. 2000.

KONG, X.; LUO, Q.; ZENG, G. LEE, M. H. **A new shape descriptor based on centroid-radii model and wavelet transform**. *Optics Communications*, v.273, n.2, p.362-366. 2007.

LANA, M.M.; VIEIRA, J.V. **Fisiologia e Manuseio Pós-Colheita de Cenoura** – 2000, 16 p. Embrapa Hortaliças; Circular Técnica; ISSN 1415-3033;21.

LARABI, S. **Textual description of shapes**. *Journal of Visual Communication and Image Representation*, v.20, n.8, p.563-584. 2009.

LEEMANS, V., & DESTAIN, M.-F. A real-time grading method of apples based on features extracted from defects. **Journal of Food Engineering**. 61: 83–89. 2004.

LIMING, X. YANCHAO, Z. **Automated strawberry grading system based on image processing**. Computers and Electronics in Agriculture, v.71, n.Supplement 1, p.S32-S39.

LOSS, L.A. Discriminação de contornos naturais através da análise de decomposições tempo-escala-frequencia. Dissertação de Mestrado. UNICAMP – 131p. 2004.

LOURO, Antônio H F ; MENDONÇA, Michelle M ; GONZAGA, A. Classificação de Tomates Utilizando Redes Neurais Artificiais. In: II Workshop de Visão Computacional – WVC'2006. **Anais...** Escola de Engenharia de São Carlos – São Carlos, v.1. p. 239-244. 2006.

MANZAN, W. A. (2006). Utilização das transformadas wavelets na extração de características e no reconhecimento de padrão em um sinal ECG. Universidade Federal de Uberlândia. Dissertação de mestrado 50 p.

MENESATTI, P.; COSTA, C.; PAGLIA, G.; PALLOTTINO, F.; D'ANDREA, S.; RIMATORI, V. AGUZZI, J. **Shape-based methodology for multivariate discrimination among Italian hazelnut cultivars**. Biosystems Engineering, v.101, n.4, p.417-424. 2008.

NAGATA, M.; TALLADA, J. G . **Quality Evaluation of Strawberries**. Computer Vision Technology for Food Quality Evaluation, v. 1, n.1, p. 265-287, 2008.

NASREDDINE, K; BENZINO, A; FABLET, R. **Shape Geodesics for the classification of calcified structures: Beyond Fourier shapes descriptors**. Fisheries Research v. 98, n. 1. p 8-15, 2009

OTSU, N. **Threshold selection method from gray-level histograms**. IEEE Trans Syst Man Cybern, v.SMC-9, n.1, p.62-66. 1979.

RASHIDI, M; SEYFI, KEYVAN. **Classification of fruit shape in cantaloupe using the analysis of geometrical attributes**. World Journal of Agricultural Sciences. V 3, n. 6, p. 735-740. 2007

REGUNATHAN, M; LEE, W. S. **Citrus fruit identification and size determination using machine vision and ultrasonic sensors**. ASAE meeting

Presentation, paper number 053017. ASAE annual International Meeting, Florida, USA, 2005.

SAS Institute Inc. **SAS/STAT 9.1 User's Guide**. Cary, USA. 2004, 5136 p.

SAS Institute Inc. **SAS/STAT 9.2 User's Guide**. The STEPDISC Procedure (Book Excerpt) Cary, USA. 2008, 36 p.

SHAHIN, M. A. TOLLNER, E. W; MCCLENDON, R. W. **Artificial intelligence classifiers for sorting apples based on watercore**. Journal of Agriculture Engineering Research. 79: 265-274. 2001.

SIMÕES, A. S.; COSTA, A. H. R. Classificação de laranjas baseada em padrões visuais. In: VI Simpósio Brasileiro de Automação Inteligente. Sociedade Brasileira de Automática – SBA. CDROM.14-17 Setembro 2003, p. 77-81.

SIMÕES, A. S.; COSTA, A. H. R.; ANDRADE, M. T. C. Utilizando um classificador fuzzy para a seleção visual de laranjas. In: Workshop de Computação – WORKCOMP'2001. **Anais...** Instituto Técnico da Aeronáutica – São José dos Campos, p. 113-117. 2001.

TORT, A. **Elliptical Fourier Functions as a Morphological Descriptor of the Genus Stenosarina (Brachiopoda, Terebratulida , New Caledonia)**. Mathematical Geology, v.35, n.7, p.873-885. 2003.

YANG, Qingsheng. Apple stem and calyx identification with machine vision. **Journal of Agriculture Engineering Research**. 63: 229-236. 1996.

ZHANG, D. LU, G. **Shape-based image retrieval using generic Fourier descriptor**. Signal Processing: Image Communication, v.17, n.10, p.825-848. 2002.

ZHANG, D. LU, G. **Review of shape representation and description techniques**. Pattern Recognition, v.37, n.1, p.1-19. 2004.

CAPÍTULO 4 AVALIAÇÃO DE DESCRITORES DE TEXTURA PARA DETECÇÃO DE RACHADURAS EM RAÍZES DE CENOURAS (*Daucus carota*)

4.1 INTRODUÇÃO

Como todo produto agrícola, a cenoura também pode sofrer danos durante o cultivo ou mesmo na colheita. Danos durante o cultivo podem ser provocados por doenças ou deficiências nutricionais, que alteram o aspecto visual do produto. No caso específico de cenouras, alguns destes danos são as rachaduras e as doenças. As rachaduras ocorrem pela irregularidade no regime hídrico, como um excesso de irrigação aplicado após um período de falta de água (MURAYAMA,1983).

Nos processos de pós-colheita, é comum a separação das cenouras de acordo com algum critério de seleção, sendo descartados os produtos defeituosos e o restante dividido em classes para comercialização, onde cada uma destas classes possui valor diferenciado na revenda. Desta forma, tanto o consumidor tem interesse em adquirir produtos com algum padrão de conformidade como o produtor tem interesse em separar produtos que obtiveram melhor classificação para obter um maior valor de mercado. Um padrão de conformidade brasileiro foi criado pela Companhia de Entrepósitos e Armazéns Gerais de São Paulo- CEAGESP e vem sendo adotado por outros entrepostos no Brasil, determinando a referência a ser adotada para aceitação da cenoura pelo mercado consumidor (CEAGESP, 2000). Neste padrão, as rachaduras são consideradas defeitos graves, e raízes que apresentem este defeito devem ser descartadas.

A separação e classificação dos produtos podem ser feitas manualmente ou por sistemas automáticos. Os sistemas manuais são tediosos, trabalhosos, inconsistentes e demorados (GUNASEKARAN, 1996). Além disto, é subjetivo, pois cada profissional envolvido no processo pode analisar de forma diferente um mesmo produto, classificando-o em categorias diferentes. Paulus (1997)

avaliou a repetibilidade de um especialista na classificação de duas variedades de maçãs, avaliando a cor, forma e tamanho. Utilizando o conjunto de 150 maçãs da variedade Golden Delicious e 900 da variedade Jonagold, o especialista realizou a classificação dos frutos duas vezes, apresentando erros expressivos entre os dois resultados (53,8% para a primeira variedade e 35,5 % para outra).

Para suprir esta subjetividade da operação humana, os sistemas de visão artificial (SVAs) vêm sendo empregados com sucesso na classificação de produtos agrícolas, disponibilizando métodos rápidos, econômicos, consistentes e objetivos, não destrutivos e com acurácia a ser obtida superior à classificação humana (BROSNAN e SUN, 2002).

Segundo Sun (2008), o crescimento da área de inspeção de produtos alimentícios tem sido incrementado pelo aumento da capacidade de processamento dos computadores e o rápido desenvolvimento de novas técnicas de processamento de imagens e softwares específicos, atraindo diversas pesquisas para esta área.

A utilização de SVAs na inspeção de produtos alimentícios pode ser comprovado em diversos trabalhos, como de Zion et al. (1999) que analisaram o formato de pescado utilizando os momentos invariantes, realizando a separação em três tipos de peixes (tainha, carpa e St. Peter), e nos trabalhos de Hu et al. (1998) e Jeyamkondam et al. (2001), que utilizaram características de textura para avaliar a maciez de filés de peixe e de carne bovina, respectivamente. Na área de frutos, uma atenção especial tem sido dada na utilização dos SVAs para classificação de maçãs e citros, devido a sua importância econômica para os Estados Unidos e Europa, como apresentado nos trabalhos de Paulus et al. (1997), Leemans et al. (1999), Shahin et al. (2001), Simões e Costa (2003), Leemans et al. (2004), Bennedsen et al. (2005), Throop e Aneshanley (2005), Blasco et al. (2007) e Blasco et al. (2009).

Outros trabalhos na classificação de características externas de outras frutas e produtos alimentícios podem ser encontradas nos trabalhos realizados com mangas (CHALIDABHONGSE et al., 2006), carambolas (ABDULLAH,

2006), tomates (SARKAR e WOLFE, 1985, JAHNS et al., 2001), bananas (MENDOZA e AGUILERA, 2004), batatas (PUN et al. , 1992; NOORDAM et al., 2000; BARNES, 2010), ostras (LEE et al., 2004), grãos de romã (BLASCO et al., 2009). Autores como Brosnan e Sun (2002), Brosnan e Sun (2004), Du e Sun (2006) e Davies (2009) apresentam revisões sobre a aplicação de SVAs na inspeção de diversos produtos alimentícios e agrícolas, tais como frutas, verduras, frangos abatidos, pizzas, produtos de panificação e queijo, dentre outros.

Os SVAs são utilizados para reconhecimento de objetos e extração de informações quantitativas de imagens digitais, permitindo assim sua utilização em aplicações de inspeção de qualidade de produtos. No caso de inspeção de produtos agrícolas utilizam-se duas características fundamentais: a cor e o formato. A partir da cor, pode-se obter algumas características do produto, como grau de maturação, variedade e a detecção de alguns defeitos na superfície, enquanto que através da forma pode-se identificar as variedades das espécies ou realizar a classificação de defeitos.

Segundo Leemans et al. (2004), a classificação de produtos agrícolas utilizando SVAs pode ser arbitrariamente dividida em quatro passos: a aquisição da imagem, a segmentação, a interpretação e finalmente a classificação do produto.

A segmentação é uma etapa importante na análise da imagem, pois particiona o conjunto de vetores de características para se obter informações sobre os conjuntos resultantes (PEDRINI, 2008). Para identificação de defeitos na superfície de produtos, o vetor de características pode ser construído a partir de valores de cor no espaço RGB, HSV ou HSI, ou ainda por descritores de textura ou por outro descritor específico para a aplicação desejada.

Deve-se reconhecer que a textura é uma propriedade do relacionamento de um pixel ou conjunto de pixels com sua vizinhança, o que caracteriza que a textura é uma propriedade territorial. Portanto, as medidas de textura são inerentemente dependentes do tamanho dos recortes obtidos da amostra de

observação e algumas precauções devem ser tomadas para que os recortes realmente representem a textura do objeto a ser segmentado.

Segundo Gonzalez & Woods (2000), existem três abordagens utilizadas para levantamento de descritores de textura, a estatística, a estrutural e a espectral.

A abordagem estatística, utilizando os descritores de Halarick, são as mais destacadas na literatura, e são facilmente implementadas em programas de computadores.

A abordagem espectral, utilizando o conceito de multiresolução pela aplicação da transformada discreta de Wavelet, permite a redução da dimensionalidade da imagem, como também o desmembramento da imagem original em quatro sub-imagens. Estas quatro sub-imagens possuem frequências diferentes entre si, permitindo maior destaque de regiões com diferentes texturas.

Já a abordagem estrutural apresenta pouca utilização na literatura, pois requer vários testes para se definir qual o melhor elemento estruturante, o tamanho, a direção e o padrão de regras utilizadas. Neste trabalho, optou-se por comparar as abordagens estatística e espectral.

Ao analisar defeitos da superfície de produtos pode-se utilizar os descritores de textura para identificar diferenças entre regiões de um mesmo objeto, podendo então ser empregados na detecção de rachaduras em raízes de cenouras.

O objetivo do trabalho foi desenvolver e testar redes neurais artificiais para identificar rachaduras em raízes de cenoura, utilizando descritores de textura de Halarick e valores de energia das imagens sub-amostradas obtidas pela aplicação da transformada Wavelet.

4.2 FUNDAMENTAÇÃO TEÓRICA

Segundo Gonzalez & Woods (2000), não existe uma definição formal para textura, mas assegura que estes descritores fornecem medidas

relacionadas com suavidade, rugosidade e regularidade. Alguns autores, como Ballard e Brow (1982) definem textura como sendo um grau de entrelaçamento entre os componentes de um objeto, ou seja, é uma medida qualitativa de quão rugoso é este entrelaçamento, no sentido de que um pano de lã é mais rugoso do que um pedaço de pano de seda nas mesmas condições de visualização. O índice de rugosidade está relacionado ao intervalo da repetição espacial da estrutura local. Um intervalo grande implica uma textura grossa; um intervalo pequeno implica uma textura fina. Este índice de percepção de rugosidade não é claramente suficiente como medida qualitativa de textura, mas pode ser usado como um guia para a identificação e diferenciação de regiões que apresentem grandezas numéricas diferentes entre si. Outra definição de textura é dada por Petrou & Sevilla (2006), que considera a textura como a variação de dados em uma escala muito menor do que o objeto de interesse, podendo ser utilizada para realizar o reconhecimento de padrões e promover a distinção entre objetos ou partes diferentes de um mesmo objeto.

Alguns autores, como Gonzalez & Woods (2000), definem três abordagens principais usadas em processamento de imagens para a descrição de textura, que são:

- Abordagem estatística: a textura é definida por um conjunto de medidas locais extraídas do padrão. Levam às caracterizações de textura como suave, áspera, granular, etc. Medidas estatísticas comuns incluem entropia, correlação, contraste e variância e média;
- Abordagem estrutural: utilizam o conceito de que texturas são compostas de primitivas dispostas de forma aproximadamente regular e repetitiva, de acordo com regras bem definidas, levando a informações sobre a disposição das primitivas em uma imagem. Como exemplo, pode-se citar a descrição da textura baseada em linhas paralelas regularmente espaçadas;
- Abordagem espectral: baseiam-se em propriedades do espectro de frequências disponíveis na imagem, sendo principalmente utilizadas na detecção de periodicidade global de uma imagem.

A seguir, serão apresentadas as abordagens estatísticas, utilizando os descritores de Halarick, e a abordagem espectral, utilizando a transformada discreta de wavelet. Neste caso, é aplicado o conceito de multiresolução, onde a imagem original é sub-amostrada a partir da aplicação de um banco de filtros, e são calculados os valores de energia destas imagens como descritores de textura.

Abordagem Estatística – Descritores de Halarick

No caso da abordagem estatística, a análise pode ser realizada a partir do histograma da imagem. Estas medidas de textura extraídas do histograma fornecem informações globais da imagem, mas apresenta a desvantagem de não levar em conta a posição relativa de um pixel em relação a outros.

Um modo de solucionar este problema é a utilização das matrizes de co-ocorrência. Uma matriz de co-ocorrência, ou GLCM (gray level co-occurrence matrices), é uma tabulação de quantas combinações diferentes de valores de intensidade dos pixels (níveis de cinza) ocorrem em uma imagem, levando-se em conta a relação entre dois pixels por vez, um chamado de pixel referência e o outro de pixel vizinho. O pixel vizinho escolhido pode ser vizinho em qualquer direção: 0° , 45° , 90° , 135° , 180° , 270° ou 315° . Também a vizinhança não precisa ser exatamente de 1 pixel, pode ser de 2, 3, ou qualquer valor. Cada pixel dentro da imagem torna-se o pixel referência, iniciando no canto superior esquerdo e procedendo até o inferior direito da imagem. Desta forma, a matriz P de co-ocorrência, representa em cada elemento $p(i,j)$ o número de vezes que ocorreu uma transição do nível de cinza Z_i para Z_j considerando a distância d entre os pixels i e j na direção θ . A matriz de co-ocorrência pode ser obtida a partir da imagem monocromática, seja pela conversão da imagem colorida em um padrão monocromático, seja utilizando apenas uma das bandas da imagem, que forneça maiores detalhes sobre determinada característica a ser utilizada. Na figura 1, são apresentados os ângulos θ para cálculo da matriz de co-ocorrência, utilizando a distância $d=1$.




Figura 1. Ângulos para o cálculo na matriz de co-ocorrência.

Essas matrizes podem ser normalizadas através da divisão de cada entrada da matriz pelo número total de pares de pontos de pixels vizinhos que satisfaçam $P(i,j,d,\theta)$. Desta forma cada valor representará a probabilidade de uma transição, na orientação θ , do nível de cinza i para o nível de cinza j , com uma distância d pixels. A notação simplificada $p_{i,j}$, dada pela equação 1, será utilizada para descrever a matriz normalizada.

$$p_{i,j} = \frac{P(i,j,d,\theta)}{\sum_i \sum_j P(i,j,d,\theta)} \quad (1)$$

Em que:

- N é o número de níveis de cinza da imagem;
- d é a distância entre um pixel e outro pixel vizinho. Assume valores de 1, 2, 3, ...
- θ direção em que é calculada a matriz. Assume valores igual a 0° , 45° , 90° e 135° .

A partir da matriz normalizada $p_{i,j}$ podem ser extraídos 14 descritores que permitem discriminar objetos que possuam representações de texturas, denominados descritores de Halarick (HALARICK et al., 1984). Outros autores, como Baraldi & Parmiggiani (1995) afirmam que somente seis descritores

apresentam maior relevância, sendo suficientes para discriminar objetos pela textura. São eles o segundo momento angular, a entropia, o contraste, a variância, a correlação e a homogeneidade. Porém, em algumas aplicações, ainda podem existir uma correlação entre estes seis descritores, como citado por Mokj & Bakar (2007), que afirmaram encontrar uma correlação inversa entre a entropia e o segundo momento angular.

Neste texto, serão apresentados quatro destes descritores, disponibilizados no pacote computacional MATLAB. O primeiro deles é o contraste, que retorna uma medida do contraste entre as intensidades de um pixel analisado e do pixel vizinho. A comparação é realizada em todos os pixels da imagem. Uma imagem que possua o mesmo tom de cinza em toda sua extensão apresenta o contraste igual a 0 (zero). O contraste reflete então a quantidade de variação local de níveis de cinza em uma imagem. Seja $p(i, j)$ a matriz normalizada obtida de uma matriz de co-ocorrência $P(i, j, d, \theta)$, a medida de contraste é definida pela equação 2.

$$\text{contraste} = \sum_i^N \sum_j^N (i - j)^2 p_{i,j} \quad (2)$$

O segundo momento angular (SMA), também conhecido como energia, fornece a medida de homogeneidade dos pixels. Uma imagem com pouca variação na distribuição dos pixels apresenta o valor de energia próximo de 1. O valor de energia pode ser calculado através da equação 3.

$$SMA = \sum_{i=1}^N \sum_{j=1}^N p_{i,j}^2 \quad (3)$$

O momento da diferença inversa denota a homogeneidade, que apresenta valores altos quando a textura apresenta pouca variação nos níveis de cinza, calculada através da equação 4.

$$homogeneidade = \sum_{i=1}^N \sum_{j=1}^N \frac{1}{1+(i-j)^2} p_{i,j} \quad (4)$$

Sendo μ_x e μ_y as médias nas direções x e y , e σ_x e σ_y os desvios-padrão, pode-se obter a correlação, apresentada na equação 5, que mede a dependência linear dos níveis de cinza nas combinações dos pares de pixels em uma determinada região.

$$correlação = \frac{1}{\sigma_x \sigma_y} \sum_{i=1}^N \sum_{j=1}^N (i - \mu_x)(j - \mu_y) p(i, j) \quad (5)$$

Abordagem Espectral

A utilização de métodos espaciais, como a GLCM, apresenta dificuldade para detectar padrões periódicos de textura, que são facilmente identificados no espectro de freqüência como pontos de alta concentração de energia. Nestes casos, a abordagem espectral, utilizando transformadas de Fourier ou de Wavelet, pode apresentar melhores resultados (CASTANÕN, 2003).

Da mesma forma que a transformada de Fourier, a transformada Wavelet permite a decomposição do sinal $x(s)$ em valores que representam a participação de cada freqüência no sinal original, porém com a vantagem de informar também em que ponto do sinal ocorre esta participação. Desta forma, a transformada Wavelet apresenta componentes de tempo, freqüência e escala.

A transformada Wavelet é formada por um conjunto de funções base, como a de Meyer, Haar, Morlet, Daubechies e outras. No processamento de sinais, escolhe-se uma destas funções, e é feita a convolução desta com o sinal original, obtendo-se a covariância entre os dois sinais. Depois, a função base é alterada na escala do tempo, e novamente é feita a convolução. Este processo é repetido k vezes, com $k=1,2,4,8,16\dots$, onde k é o fator de escala

que altera a escala do tempo da função base. Este processo é ilustrado na figura 2.

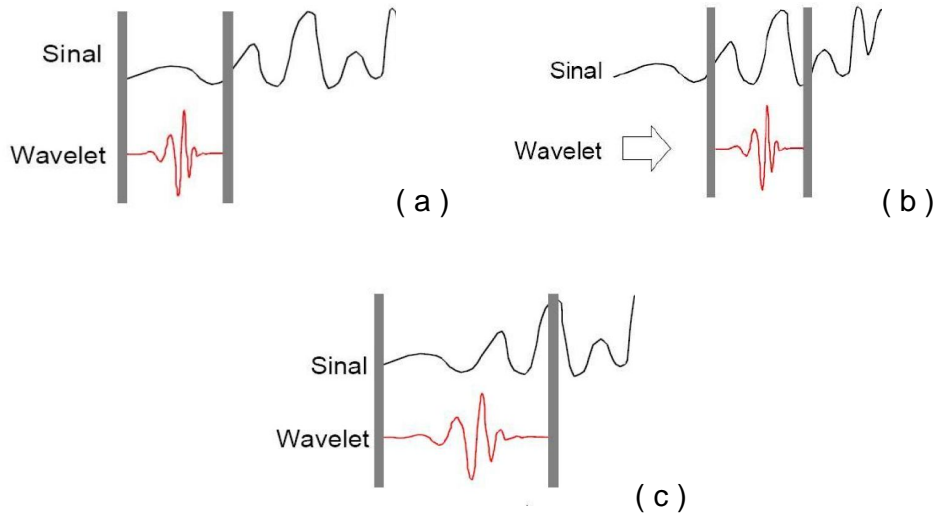


Figura 2. (a) Correlação da wavelet mãe $\psi(t)$ com o sinal $s(t)$; (b) deslocamento da wavelet $\psi(t)$ para a direita e (c) dilatação da wavelet $\psi(t)$ para um novo fator de escala e novamente aplicado ao sinal original (Mathworks, 1996)

Matematicamente, o wavelet é definido como uma função $\psi \in L^2(\mathbb{R})$ com média zero, e a transformada Wavelet é definida na equação 6.

$$Wf(u, s) = \langle f, \psi_{u,s} \rangle = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{|s|}} \psi^* \left(\frac{t-u}{s} \right) dt \quad (6)$$

Em que:

u e s são dois parâmetros reais

* indica o conjugado complexo.

O valor s é chamado de parâmetro de translação e indica o deslocamento s da função $\psi(t)$ no eixo t , e o valor de u é denominado de parâmetro de escala, alterando a escala da função $\psi(t)$. Se $\psi_{u,s}(t)$ for definida

pela equação 7, então a transformada Wavelet pode ser reescrita como o produto interno das funções $f(t)$ e $\psi_{u,s}(t)$, definido pela equação 8.

$$\psi_{u,s}(t) = \frac{1}{\sqrt{|s|}} \psi\left(\frac{t-u}{s}\right) \quad (7)$$

$$Wf(u,s) = \langle f(t), \psi_{u,s}(t) \rangle = \int_{-\infty}^{+\infty} f(t) \psi_{u,s}(t) dt \quad (8)$$

A função resultante Wf é um descritor de forma que é invariante à rotação, translação, escala e se o objeto é convexo ou não (KONG et al., 2007).

A função $\psi_{1,0}(t)$ é chamada de wavelet mãe, enquanto que as outras funções $\psi_{u,s}(t)$ para $u \neq 1$ e $s \neq 0$ são chamadas de wavelets filhas. Dentre as funções $\psi(t)$ utilizadas, a mais conhecida é a de Haar, apresentada na equação 9.

$$\psi(t) = \begin{cases} 1 & , \quad \text{se } 0 \leq t \leq \frac{1}{2} \\ -1 & , \quad \text{se } \frac{1}{2} \leq t \leq 1 \\ 0 & , \quad \text{caso contrário} \end{cases} \quad (9)$$

A função de Haar original $\psi_{1,0}(t)$, e a função de Haar deslocada no eixo t , $\psi_{1,1}(t)$ são apresentadas na figura 3.




Figura 3. (a) Gráfico da função de Haar $\psi_{1,0}(t)$, na posição inicial e (b) $\psi_{1,1}(t)$, deslocada no eixo t

Uma das aplicações da transformada Wavelet no processamento de imagens é o conceito de multiresolução, onde uma imagem com muitos detalhes pode ser decomposta em sub-imagens com escalas diferentes da original.

A relação entre os conceitos de multiresolução e a transformada Wavelet foi desenvolvida inicialmente por Mallat (1989), que propôs um Codificador Sub-Banda de Dois Canais, que é uma forma eficiente de se obter os coeficientes da Transformada de Wavelet, representando para esta o que a Transformada Rápida de Fourier representa para a Transformada de Fourier.

O conceito de multiresolução permite extrair da imagem somente as informações necessárias para a sua representação. Um exemplo é apresentando em Oliveira e Palomo (2005), que relatam que para visualizar quais áreas de uma imagem aérea possuem cobertura vegetal necessita-se de um número de detalhes muito menor do que quando se deseja determinar o número de árvores existentes em determinada praça.

A extensão da aplicação da transformada Wavelet para o caso 2-D é obtido pela aplicação de um conjunto de filtros 1-D. Na prática, a transformada Wavelet para imagens é calculada aplicando-se um banco de filtros passa-altas (Hi_D) e passa-baixas (Lo_D) à imagem, conforme apresentado na figura 4.

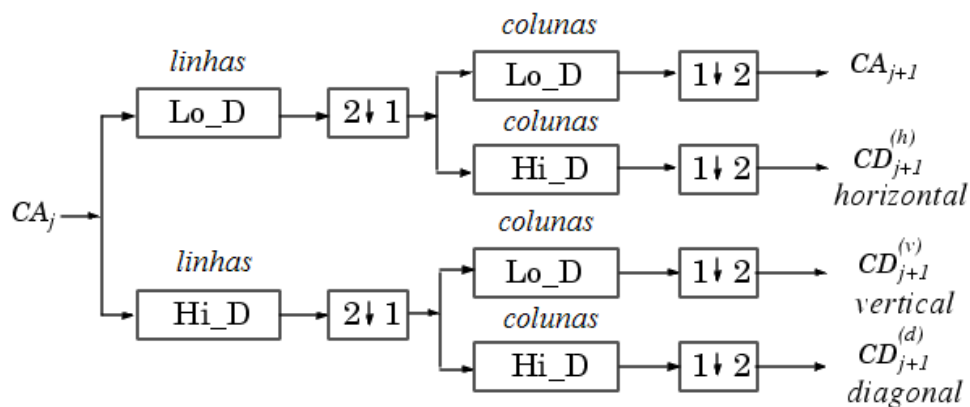


Figura 4. Diagrama da composição sucessiva da imagem CA_j em aproximações e detalhes através da aplicação sucessiva de bancos de filtros passa-alta e passa baixa.

As equações 10, 11, 12 e 13 detalham a aplicação destes filtros em uma imagem digital:

$$CA_{j+1} = [Lo_D_{lin} * [Lo_D_{col} * CA_j]_{\downarrow 2,1}]_{\downarrow 1,2} \quad (10)$$

$$CH_{j+1} = [Lo_D_{lin} * [Hi_D_{col} * CA_j]_{\downarrow 2,1}]_{\downarrow 1,2} \quad (11)$$

$$CD_{j+1} = [Hi_D_{lin} * [Hi_D_{col} * CA_j]_{\downarrow 2,1}]_{\downarrow 1,2} \quad (12)$$

$$CV_{j+1} = [Hi_D_{lin} * [Lo_D_{col} * CA_j]_{\downarrow 2,1}]_{\downarrow 1,2} \quad (13)$$

Em que:

- * é o operador de convolução;
- CA_j é a imagem original;
- Lo_D são filtros passa alta
- Hi_D filtros passa baixa
- ↓_{2,1} é o operador de sub-amostragem.
- lin e col representam a direção de aplicação do filtro, em linhas ou colunas

O operador (↓_{1,2}) aplicado a uma função discreta reduz o seu número de elementos pela metade, recuperando apenas os elementos em posições pares:

$$(\downarrow_2)x(n) = x_0, x_2, x_4, \dots \quad (14)$$

Quando aplicados a uma imagem digital, o operador (↓_{2,1}) indica que de cada duas colunas, uma será utilizada e a outra descartada, e o operador (↓_{1,2}) indica que de cada duas linhas, uma é utilizada e a outra é descartada.

O conjunto de saída da decomposição Wavelet, formado pelo conjunto de imagens CA_{j+1} , CV_{j+1} , CH_{j+1} e CD_{j+1} representam os dados suavizados ou de baixa frequência (LL) e mais três conjuntos de detalhes, sendo estes conjuntos direcionais de alta frequência na horizontal (HL), vertical (LH) e diagonal (HH), respectivamente.

O conjunto CA_{j+1} é uma aproximação sub-amostrada da imagem original. Já os conjuntos CV_{j+1} , CD_{j+1} e CH_{j+1} também são sub-amostragens da imagem original, porém esses contêm os detalhes que, somados a CA_{j+1} , reconstróem a imagem original. Nas imagens dos coeficientes de alta frequência, os coeficientes mais escuros representam as regiões de menor resposta aos filtros enquanto que os coeficientes mais claros representam as regiões de alta resposta do filtro.

No trabalho de Mallat (1989), as funções de detalhe decompostas são assim descritas:

- detalhes na vertical: foram aplicados um filtro passa-altas nas linhas e um passa-baixas nas colunas;
- detalhes na horizontal: aplicados um filtro passa-baixas nas linhas e um passa-altas nas colunas;
- detalhes na diagonal: aplicados um filtro passa-altas nas linhas e nas colunas.

Uma outra representação da decomposição das imagens em sub-imagens pela aplicação da transformada discreta de Wavelet (DWT) é citada em alguns trabalhos, como em Arivazhagan & Ganesan (2003), e é aqui rerepresentada na figura 5, usando a terminologia que representa os filtros utilizados em cada decomposição. Na figura 5(a) temos a representação da imagem original I, em 5(b), após a aplicação da DWT. Em 5(c) é apresentada a segunda decomposição, aplicado no componente LL_x .




Figura 5. (a) Imagem original, (b) resultado da decomposição de uma imagem I pela DWT e (c) aplicando a DWT na imagem LL₁ (ARIVAZHAGAN & GANESAN, 2003)

O banco de filtros pode ser aplicado sucessivamente, obtendo-se k conjuntos de imagens, sendo k=1, 2, 3..., resultando em 4k imagens LL_k, LH_k, HL_k, HH_k. O número de decomposições da imagem é um fator crítico no processo, pois pode ocorrer perda de informação. Uma alternativa proposta por Chang e Kuo (1992) recomenda proceder com uma decomposição, calcular a energia de cada subimagem e verificar se o resultado apresenta separabilidade entre as classes. Em caso negativo, continuar com a decomposição até se atingir uma subimagem com um valor mínimo de 16x16 pixels, pois considera que abaixo deste valor o resultado da decomposição não é satisfatório.

Os descritores de textura podem ser extraídos de todas ou qualquer uma das imagens resultantes. Estes descritores podem ser os de Halarick, obtidos pela matriz de co-ocorrência, ou ainda os valores de energia das imagens (CHANG e KUO, 1992), fornecida pela equação 15.

$$energia = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N |I(i, j)| \quad (15)$$

Em que:

M e N são as dimensões da imagem;

I (i,j) é o valor do pixel na coordenada (i,j) da imagem I ;

Outro descritor de textura que pode ser obtido é a mistura das duas abordagens tratadas neste trabalho. Primeiramente, são extraídas as sub-bandas da imagem original utilizando a transformada wavelet e a partir da sub-banda de maior energia, é gerada a matriz de co-ocorrência e calculados os descritores de textura estatísticos. Latif-Amed et al. (2000) utilizaram esta metodologia para detectar defeitos em tecidos, comparando os descritores estatísticos extraídos da imagem original e da sub-banda que apresentava maior energia, sendo que o segundo método ofereceu melhores resultados. Mokji & Bakar (2007) também utilizaram este método aplicado a texturas de Brodatz, e concluíram que a aplicação conjunta da transformada wavelet e dos descritores de Halarick resultaram em ganho computacional e em melhores resultados na classificação.

Classificação de padrões utilizando Redes Neurais Artificiais

Os descritores de textura obtidos são apresentados na forma de vetores do tipo $X = [x_1, x_2, \dots, x_n]$ que, no presente trabalho, serão posteriormente processados por sistemas classificadores baseados em redes neurais artificiais (RNAs). Segundo Gonzalez & Woods (2000), as RNAs têm a vantagem de gerar planos não-lineares para separação das classes, enquanto os classificadores estatísticos geram planos lineares ou quadráticos. As RNAs são sistemas paralelos distribuídos por unidades e processamento simples (neurônios) que calculam determinadas funções matemáticas. Estes neurônios são dispostos em camadas e interligados entre si. Nestas conexões, pode ser aplicado um peso, utilizado para ponderar a participação de cada sinal na ativação de um determinado neurônio. Na figura 6 é apresentado um neurônio artificial, x é o vetor de entrada, w são as ligações sinápticas entre os neurônios, b é a polarização e y a saída do neurônio.

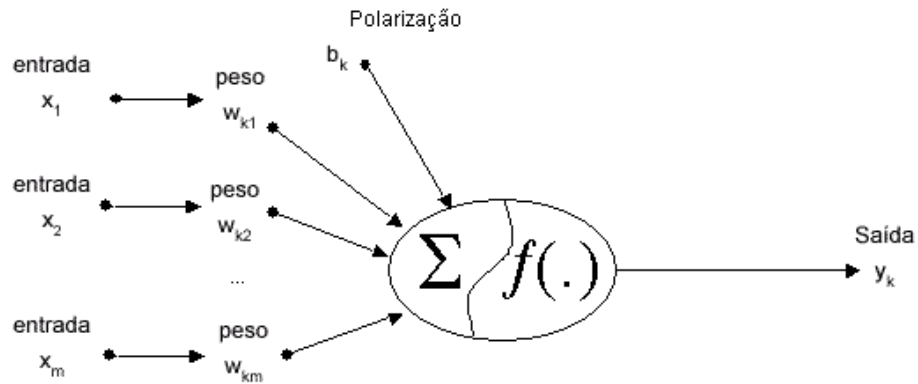


Figura 6. Representação de um neurônio artificial.

A saída do neurônio é definida pelo seu valor de ativação calculado da seguinte forma:

$$v_j = f\left(b_j + \sum_{i=1}^m w_{ji} x_i\right) \quad (16)$$

Em que:

- v é o valor de ativação do neurônio k ;
- w são os pesos das conexões do neurônio k ;
- x é o valor de cada um dos m estímulos que chegam ao neurônio k ;
- b é o valor de polarização que será somado ao valor das entradas para compor o valor de ativação.
- f é uma função de ativação, que pode ser sigmoïdal, logarítmica, linear ou outra.

Existem na literatura diversas arquiteturas de redes, que definem o número de camadas, como os dados percorrem os neurônios ou de acordo com sua conectividade (BRAGA et al., 2000). Uma das arquiteturas mais utilizadas é o perceptron de multicamadas, apresentado na figura 7.

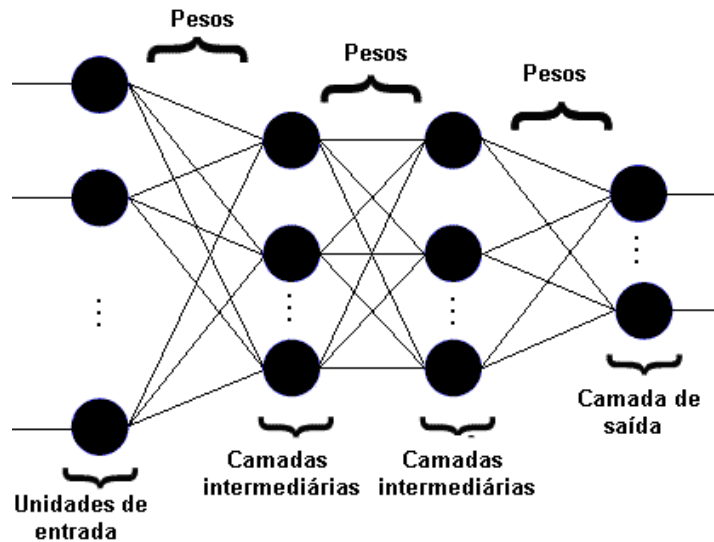


Figura 7. Representação de uma rede do tipo alimentada adiante com multicamadas.

Para programar uma RNA, deve-se definir o tipo e a arquitetura da rede, que é o número de camadas intermediárias e a quantidade de neurônios em cada uma. As RNAs possuem a capacidade de aprender através de exemplos, utilizando um algoritmo de aprendizado. Este aprendizado é supervisionado, e consiste na definição dos parâmetros livres (pesos sinápticos e polarizações) para um determinado problema. Um dos algoritmos de treinamento mais utilizados é o da retropropagação do erro, que executa um processamento iterativo em um conjunto de treinamento, comparando para cada amostra, o valor da saída da rede com o valor desejado da classe da amostra. A partir desta comparação, é calculado o erro quadrático médio que é retropropagado pela rede, no sentido da camada de saída até a camada de entrada, modificando os parâmetros livres, de forma a minimizar o erro. Em geral, esses parâmetros convergem para valores que tornam o erro aceitável e o treinamento é finalizado.

Para evitar o treinamento excessivo da rede e assim não comprometer a capacidade de generalização desta, os dados de treinamento são divididos em dois, um para realizar o treinamento e outro para teste. Desta forma, a rede é treinada com um conjunto de dados e sua acurácia é avaliada por outro conjunto. Uma técnica utilizada para avaliação de um classificador com RNAs é

a validação cruzada múltipla, com o método “deixe um de fora”. Neste caso, se temos N exemplos no conjunto de teste, N-1 exemplos são usados para treinar o modelo, e o modelo é validado testando-o sobre o exemplo deixado de fora. O experimento é repetido para um total de N vezes, cada vez deixando de fora um exemplo diferente para a validação. O erro quadrado na validação é então a média sobre as N tentativas do experimento (HAYKIN, 2001 e Bishop, 1995).

Para avaliação do desempenho dos classificadores, é adotada a matriz de confusão e calculado o coeficiente kappa (CONGALTON, 1991). O valor de kappa igual a 1 ocorre quando existe uma classificação perfeita, e o kappa igual a zero ocorre para uma classificação realizada ao acaso.

4.3 MATERIAL E MÉTODOS

A aquisição de imagens foi realizada na Embrapa Hortaliças, em Brasília-DF. Foram adquiridas 50 imagens digitais de raízes de cenouras utilizando uma câmera DBK41B, da The Imaging Source, com interface USB, e o software de captura IC Capture. As cenouras foram colocadas em uma câmara de iluminação composta de seis lâmpadas fluorescentes Philips de uso comum, de 40 watts cada, forrada internamente com fórmica cinza fosca.

Posteriormente, o trabalho de análise de imagens foi realizado no Laboratório PROVISAGRO, da Universidade Federal de Viçosa, em Viçosa-MG. Para o desenvolvimento do trabalho, foram selecionadas 10 imagens com rachaduras e 10 sem rachaduras para o treinamento do classificador, e 15 imagens com rachaduras e 15 sem rachaduras para validação do sistema.

Uma análise da imagem de uma raiz de cenoura para detectar as rachaduras pode apresentar falsos positivos, pois uma variação na coloração da raiz ou a ocorrência de outro tipo de defeito pode resultar em diferenças de textura na imagem. Como a rachadura é um defeito que ocorre no sentido do comprimento da raiz, a área atingida é maior do que alguns pequenos defeitos ocasionados por pequenas lesões ou outra anomalia que possa ocasionar pequenas regiões defeituosas.

Para contornar este problema de detecção de defeitos localizados em pequenas áreas, as imagens foram recortadas em fatias verticais, de onde se extraíram os descritores de textura estatísticos e espectrais. Após toda a etapa de desenvolvimento do classificador, cada uma das fatias foi classificada como apresentando um defeito ou não.

Após este processo, cada imagem foi reconstruída a partir dos recortes classificados. Após esta reconstrução, foram consideradas como defeituosas as imagens que apresentaram determinado número N de recortes contíguos detectados como rachaduras. Para determinação do valor de N, foram avaliados a combinação de dois a cinco recortes contíguos classificados como rachaduras, determinando se a raiz realmente pode ser classificada como uma raiz defeituosa.

Para desenvolvimento dos classificadores, para cada grupo de descritores, foi utilizada a rotina STEPDISC do SAS para selecionar apenas aqueles que melhor discriminavam a existência de rachaduras nos recortes. Depois de selecionados, os descritores foram aplicados a uma RNA para treinamento e definição da melhor arquitetura e dos parâmetros da rede.

Para realizar a classificação, foi utilizada uma rede neural do tipo alimentada adiante de duas camadas. Foram testadas diversas configurações de rede, variando a camada intermediária de dois a 20 nós. A camada de saída foi mantida com dois nós, representando as classes “com rachadura” e “sem rachadura”.

Das 20 imagens selecionadas para treinamento do classificador, foram extraídos 60 recortes de partes sadias das raízes e 60 recortes de partes apresentando rachaduras. Para treinamento da rede foi utilizada a técnica de validação cruzada múltipla com o método “deixe um de fora”, dividindo-se novamente o conjunto de treinamento em 8 subconjuntos. Durante o processo de treinamento da rede, 7 destes subconjuntos foram utilizados para treinamento, e o subconjunto restante para teste. Os subconjuntos foram rotacionados entre si, desta forma a rede foi treinada 8 vezes.

Depois de escolhida a melhor arquitetura de rede para cada grupo de descritores, foi realizada a etapa de validação do sistema com as 15 imagens de cenoura com rachaduras e 15 sem rachaduras. As imagens foram recortadas, obtendo-se 160 recortes, sendo que destes, 80 apresentaram defeitos de rachaduras nas raízes. Estes recortes foram aplicados à RNA selecionada e classificados como sendo recortes de regiões com rachaduras ou de regiões saudias.

O fluxograma da figura 8 apresenta um resumo dos procedimentos. A seção a seguir descreve detalhadamente o recorte das imagens.

Recortes das imagens

As etapas deste processo são apresentadas no fluxograma da figura 9. Para obtenção dos recortes, a imagem original RGB foi transformada para o espaço de cor HSV. A banda S apresentou melhor definição entre a raiz e o fundo, e foi selecionada para realizar a limiarização utilizando o método de Otsu. As imagens limiarizadas foram recortadas em fatias verticais com 40 pixels de largura, sendo isolada apenas a seção retangular pertencente à raiz da cenoura.

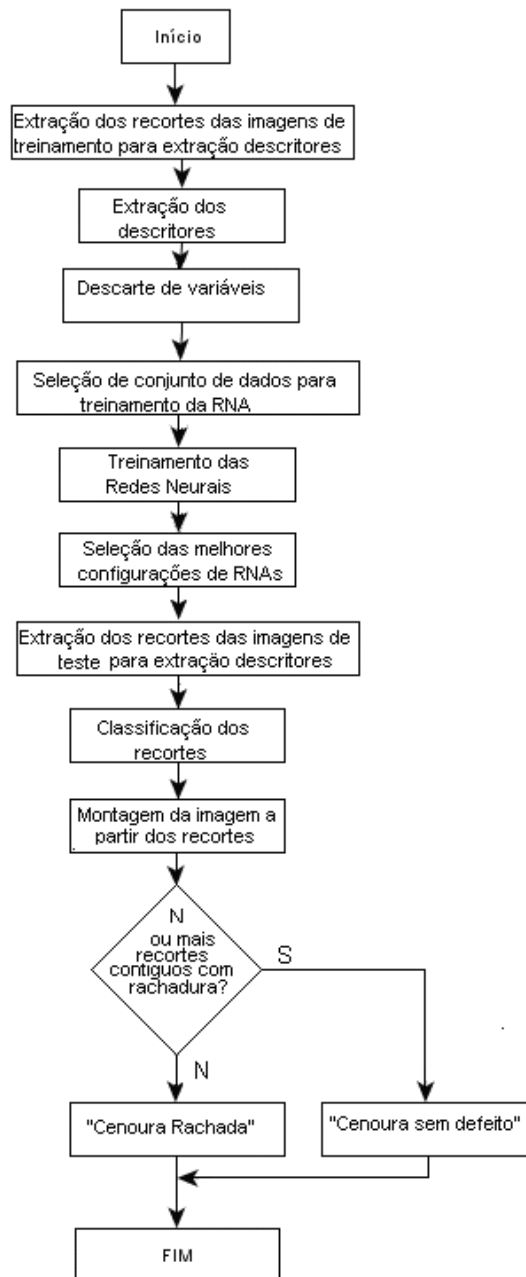


Figura 8. Fluxograma do processo de desenvolvimento do classificador de raízes de cenoura com rachaduras.

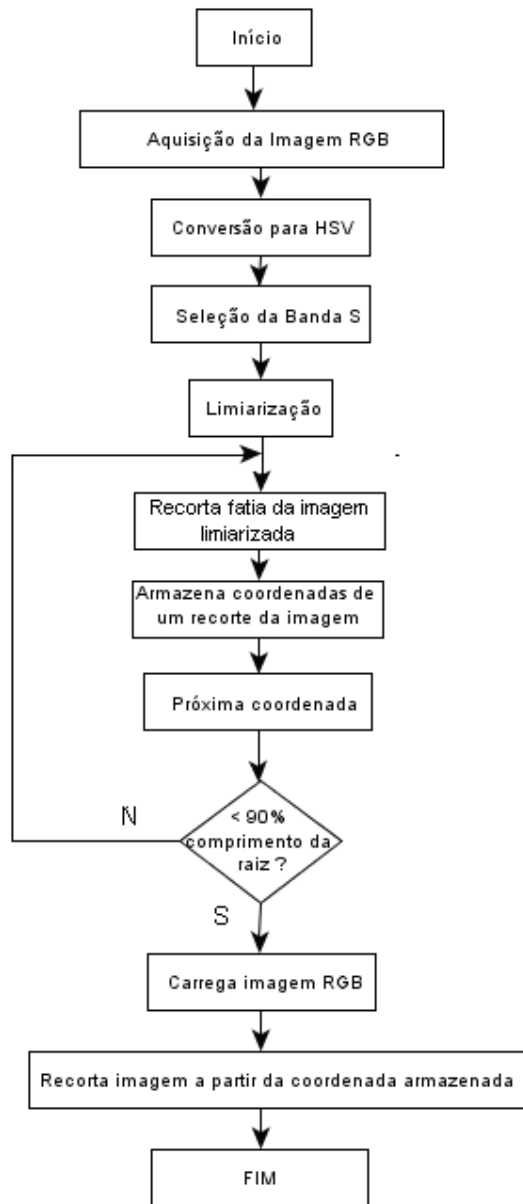


Figura 9. Fluxograma apresentando o processo de obtenção dos recortes da imagem original.

Para cada um destes recortes, foram tomados os quatro pares coordenados (x_i, y_i) , (x_f, y_f) , (x_{i+1}, y_{i+1}) , e (x_{f+1}, y_{f+1}) que indicam as coordenadas do recorte na imagem limiarizada, tomando-se a precaução de se ter $x_i = x_f$ e $x_{i+1} = x_{f+1}$, e escolhendo o maior valor entre y_i e y_{i+1} e o menor entre y_f e y_{f+1} , de forma a se obter um recorte interno ao contorno da raiz de cenoura, formando pequenos retângulos, como no detalhe apresentado na figura 10.




Figura 10. Detalhe do recorte de uma imagem limiarizada que seja interno ao contorno da raiz de cenoura.

O primeiro recorte foi tomado a 10% do comprimento a partir do ombro da raiz, e o último próximo a 10% do ápice. Estas coordenadas tomadas da imagem limiarizada foram utilizadas para extrair recortes da imagem original RGB e da imagem em tons de cinza obtidas pela conversão da imagem RGB. A partir dos recortes da imagem RGB, foi aplicada a transformada Wavelet e calculados os descritores de energia de cada sub-banda. A partir da imagem em tons de cinza foram extraídos os quatro descritores estatísticos de textura (homogeneidade, contraste, correlação e energia). Das 20 imagens utilizadas para treinamento da RNA, foram selecionados aleatoriamente 60 recortes de imagens sem apresentar rachaduras e 60 recortes com rachaduras.

4.4 RESULTADOS E DISCUSSÃO

Limiarização das imagens

Na figura 11 são apresentados os histogramas das bandas das imagens RGB e HSV. Pela inspeção visual destas figuras, a banda S da imagem HSV apresenta a maior separação entre fundo e objeto, e desta forma foi selecionada para realizar a limiarização das imagens.

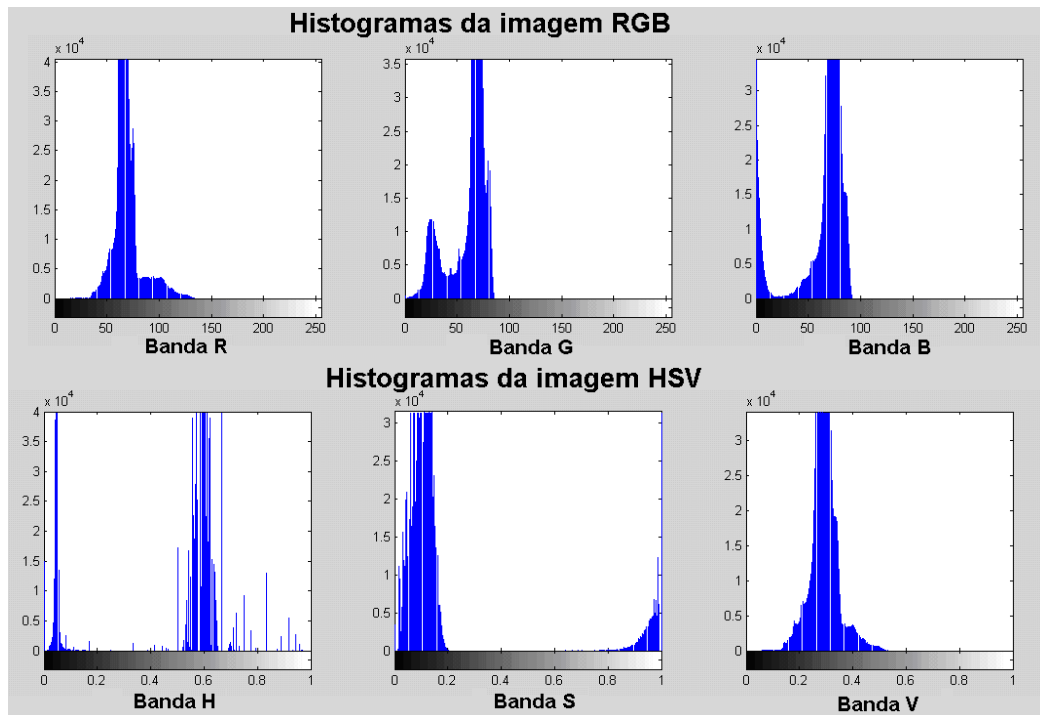


Figura 11. Histogramas individualizados para cada banda das imagens RGB e HSV.

Na figura 12 são apresentadas todas as etapas da limiarização, onde a imagem original foi convertida para o espaço HSV, selecionada a banda S e limiarizada.



Figura 12. Etapas do processo da limiarização das imagens. (a) Imagem RGB. (b) imagem HSV (c) Imagem da banda S e (d) Imagem limiarizada

Abordagem Espectral

A transformada Wavelet utilizando a função de Haar foi aplicada três vezes a cada um dos recortes, e após cada decomposição da imagem, foram calculados os valores de energia para cada uma das sub-imagens CA_j , CV_j , CD_j e CH_j , com $j=1,2$ e 3 , resultando assim em um vetor com 12 características.

Um recorte de uma imagem original é apresentada na figura 13 e as imagens das sub-imagens CA_1 , CV_1 , CD_1 e CH_1 são apresentadas na figura 14.



Figura 13. Recorte de uma imagem de uma raiz de cenoura com rachadura




Figura 14. (a) sub-imagem CA_1 ; (b) sub- imagem CD_1 ; (c) sub- imagem CH_1 ; (d) sub- imagem CV_1

Para realizar o descarte de variáveis, foi utilizado o método passo-a-passo, realizado através do procedimento STEPDISC do SAS (SAS, 2004). O algoritmo inicia com um modelo sem nenhuma variável, e são escolhidas as variáveis que irão sair ou permanecer de acordo com o teste F. O teste F parcial checa se a variável absorverá uma quantidade significativa da variação em relação àquela absorvida por outras variáveis. Para isto avalia se o valor F obtido em um dado passo satisfaz o mínimo, e se satisfizer, a variável será incluída no modelo. A cada passo entra uma variável que contribui com o maior poder de discriminação e a variável que menos contribuiu ao poder discriminante é afastada. O Quadro 1 apresenta o resultado do descarte de variáveis. O termo CX_n indica que é a sub-imagem X na n-ésima decomposição.

Quadro 1: Resultado da seleção dos descritores espectrais

Passo	Variável Seleccionada	Valor do teste F
1	CH_3	166,62
2	CA_1	18,91
3	CD_1	6,15
4	CD_2	10,97

Esta etapa de descarte permitiu selecionar apenas 4 descritores discriminatórios dentre os 12 inicialmente calculados.

As imagens com texturas periódicas apresentam frequências intermediárias, e a decomposição da imagem pela aplicação do banco de filtros ressaltam as frequências intermediárias. Desta forma, as rachaduras, que se apresentam como variações de bordas nos sentidos horizontais e diagonais em cada recorte, influenciam principalmente as sub-imagens CH_n e CD_n . Dos 12 descritores propostos inicialmente, o processo de seleção de variáveis selecionou 3 descritores pertencentes à sub-imagens CD_n e CH_n , confirmando

que estas sub-imagens podem ser utilizadas para a classificação de imagens de cenouras com rachaduras.

A sub-imagens CA_n são versões sub-amostrada da imagem original, porém, devido à aplicação do filtro passa-baixa, apresenta uma suavização na imagem, ocasionando a redução do número de níveis de cinza de cada banda e a minimização de ruídos. As altas frequências, que correspondem às transições rápidas, são atenuadas. A imagem resultante apresenta então um maior destaque entre a região sadia da raiz e a rachadura, alterando assim o valor da energia calculada na região. A primeira imagem sub-amostrada CA_1 foi também selecionada como um descritor discriminatório para a detecção de rachaduras nas imagens de raízes de cenouras.

O vetor de entradas contendo foi composto pelos descritores que foram selecionadas pela rotina de descarte, CA_1 , CD_1 , CD_2 , CH_3 , extraídos dos 160 recortes de imagens selecionados para validação, e aplicadas às arquiteturas de RNA's propostas. O Quadro 2 apresenta o resultado com as cinco melhores arquiteturas de rede que obtiveram melhor resultado na classificação.

Quadro 2. Configurações de RNAs que obtiveram melhor resultado na classificação

Número de nós da camada intermediária	Coefficiente Kappa	Exatidão Global
11	0,887 _a	94,37%
13	0,875 _a	93,75%
19	0,875 _a	93,75%
15	0,862 _a	93,13%
16	0,862 _a	93,13%

Os coeficientes Kappa seguidos de uma mesma letra não diferiram pelo teste Z a 5% de probabilidade

Verificou-se que as RNAs apresentadas no Quadro 2 obtiveram resultados semelhantes, tanto para a exatidão global como para o coeficiente Kappa. As redes que não foram apresentadas no Quadro 2 obtiveram exatidão

global menor do que 85%. Selecionando a rede com 11 nós na camada intermediária, foi obtida a matriz de confusão do Quadro 3. Nesta matriz, observou-se que não ocorreram erros de comissão e omissão elevados, indicando que o classificador obteve bons resultados na classificação.

Quadro 3. Matriz de confusão da classificação utilizando os descritores espectrais e uma RNA com 11 neurônios na camada intermediária

		Dados de Referência			Erro Inclusão (%)
		Sem Rachadura	Com Rachadura	Σ	
Resultado da Classificação	Sem Rachadura	76	4	80	5,00%
	Com Rachadura	5	75	80	6,25%
Σ		81	79	Total Acertos 151	Exatidão Global 94,37%
Erro Omissão (%)		6,17%	5,06%		

Os problemas de iluminação durante a aquisição das imagens ocasionaram sombras que dificultaram o reconhecimento das bordas pertencente ao contorno das raízes e das bordas pertencentes às rachaduras. Empregando-se o recorte das fatias de imagens somente da parte interna ao contorno das raízes minimizou este problema. Uma sugestão de melhoria no sistema de aquisição de imagens seria dispor quatro lâmpadas na parte superior da caixa e duas lâmpadas em cada lateral, provocando uma iluminação que diminuísse as sombras.

Desta forma, podemos concluir que a utilização dos descritores espectrais de textura obtidos pela aplicação da decomposição da imagem utilizando a transformada Wavelet obtiveram bons resultados, indicando sua utilização na detecção de rachaduras em imagens digitais de raízes de cenouras.

Abordagem Estatística

Para a extração dos descritores estatísticos de textura, foram calculadas as matrizes de co-ocorrência de cada recorte de imagem monocromática obtida a partir da imagem monocromática, mantendo a distância igual a um e utilizando os ângulos de 0°, 45°, 90°, 135°. Para otimização dos cálculos, a imagem foi reamostrada para uma resolução radiométrica de 6 bits, para se ter apenas 64 tons de cinza. A partir desta, foram obtidos os descritores de contraste, homogeneidade, correlação e energia de cada uma dos 4 ângulos, resultando em 16 descritores. Estes descritores foram aplicados à análise de seleção STEPDISC do SAS para realizar o descarte de variáveis. Foram selecionadas as variáveis homogeneidade para os ângulos de 0°, 45° e 135°, e contraste para 0° e 90° (Quadro 4).

Quadro 4. Configurações de RNAs que obtiveram melhor resultado na classificação

Passo	Variável Selecionada	Valor do teste F
1	Contrast ₉₀	34,49
2	Homog ₀	10,95
3	Contrast ₀	8,04
4	Homog ₄₅	4,54
5	Homog ₁₃₅	9,18

O vetor resultante foi aplicado ao mesmo procedimento adotado para o vetor de descritores espectrais. No Quadro 5 estão as cinco configurações de RNA que obtiveram melhor resultado na classificação.

As redes que não foram apresentadas no Quadro 5 obtiveram exatidão global menor do que 80%. Como os valores de classificação não diferem estatisticamente, foi selecionada a rede de configuração mais simples, apresentando 4 nós na camada intermediária. O Quadro 6 apresenta a matriz de confusão resultante para esta configuração.

Quadro 5. Configurações de RNAs que obtiveram melhor resultado na classificação

Número de nós da camada intermediária	Coefficiente Kappa	Exatidão Global
9	0,900 _a	95,00%
11	0,900 _a	95,00%
19	0,875 _a	93,75%
16	0,875 _a	93,75%
4	0,875 _a	93,75%

Os coeficientes Kappa seguidos de uma mesma letra não diferiram pelo teste Z a 5% de probabilidade.

Quadro 6. Matriz de confusão da classificação utilizando os descritores estatísticos para uma RNA com 4 neurônios na camada intermediária

		Dados de Referência			
		Sem Rachadura	Com Rachadura	Σ	Erro Inclusão (%)
Resultado da Classificação	Sem Rachadura	78	2	80	2,50%
	Com Rachadura	6	74	80	7,55%
Σ		84	76	Total Acertos	Exatidão Global
Erro Omissão (%)		7,14%	2,63%	152	95,00%

A presença de rachaduras nas imagens em tons de cinza resulta em variações na distribuição dos pixels, o que foi detectado pelos descritores de homogeneidade e contraste, que representam a variação nos níveis de cinza de uma imagem. Uma imagem de uma cenoura sadia apresenta maior uniformidade na matriz de co-ocorrência.

Os descritores utilizados apresentaram bons resultados na separação das classes, o que resultou em configurações de RNAs simples, apresentando resultados satisfatórios de classificação.

Classificação das raízes

Foram utilizadas 15 imagens de raízes sem rachaduras e 15 imagens de raízes apresentando rachaduras, que foram classificadas pelo sistema desenvolvido.

A figura 15 apresenta duas imagens reconstruídas a partir dos recortes, uma apresentando uma imagem de uma raiz sadia e outra, uma imagem de uma raiz com rachadura. A figura 15(a) apresenta 4 recortes contíguos que foram classificados como sendo rachaduras. Como estes recortes foram contíguos, a raiz foi classificada como rachadura. A figura 15(b) apresenta dois recortes que foram classificados como sendo de rachaduras, mas como não são contíguos, a cenoura foi corretamente classificada como sendo uma raiz sadia.




Figura 15. (a) Cenoura classificada como apresentando rachadura; (b) cenoura classificada como sadia

O Quadro 7 apresenta o resultado da classificação das raízes considerando o número N de recortes contíguos necessários para se determinar a raiz como sendo defeituosa. Para classificação dos recortes, foram utilizados os descritores espectrais e uma RNA de 11 nós na camada intermediária.

Quadro 7. Resultado da classificação das raízes de acordo com o número de blocos contíguos classificados como rachaduras (com descritores espectrais).

Num. De recortes contíguos com rachaduras	Exatidão Global
2	86,66%
3	93,33%
4	86,66%
5	83,33%

O Quadro 8 apresenta o resultado utilizando os descritores estatísticos utilizando uma RNA de 4 nós na camada intermediária.

Quadro 8. Resultado da classificação das raízes de acordo com o numero de blocos contíguos classificados como rachaduras (com descritores estatísticos)

Num. De recortes contíguos com rachaduras	Exatidão Global
2	86,66%
3	93,33%
4	86,66%
5	83,33%

Observando os Quadros 7 e 8 verifica-se que o número de recortes contíguos interfere no resultado da classificação. Os resultados de exatidão para classificação das raízes de acordo com o numero de recortes contíguos é igual para os dois sistemas, pois os resultados de exatidão global na classificação dos recortes, apresentados nos Quadros 3 e 6, são semelhantes.

Para os dois grupos de descritores utilizados, o classificador apresentou melhores resultados quando foram utilizados 3 recortes contíguos para confirmação de que a raiz apresenta rachadura.

4.5 CONCLUSÕES

A utilização da transformada wavelet para redução da resolução e extração da energia total de cada sub-imagem amostrada apresentou resultados satisfatórios, apresentando um índice de acertos na classificação dos recortes de 94,37% e coeficiente Kappa de 0,887.

A utilização dos descritores de textura de Halarick com 64 níveis de cinza também apresentou resultados satisfatórios, com índice de acertos na classificação dos recortes de 95,00 % e coeficiente Kappa de 0,875, indicando

que quaisquer das duas metodologias podem ser utilizadas para identificação de rachaduras em raízes de cenouras.

A metodologia proposta definiu que são necessários no mínimo 3 recortes contíguos classificados como sendo rachaduras para definir a raiz como defeituosa, obtendo uma exatidão de 93,33% na classificação das raízes como apresentando ou não as rachaduras.

4.6 REFERÊNCIAS BIBLIOGRÁFICAS

ABDULLAH, M. Z.;MOHAMAD-SALEH, J.;FATHINUL-SYAHIR, A. S. MOHD-AZEMI, B. M. N. **Discrimination and classification of fresh-cut starfruits (*Averrhoa carambola* L.) using automated machine vision system.** Journal of Food Engineering, v.76, n.4, p.506-523, 2006.

ARIVAZHAGAN, S., GANESAN, L. **Texture classification using wavelet transform.** Pattern Recognition Letters 24(9-10): 1513-1521.2003.

BALLARD, D.H. BROWN, C.M., Computer Vision., Prentice-Hall, Englewood Cliffs, NJ. 544p, 1982.

BARALDI, A. PARMIGGIANI, F. **An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters.** Geoscience and Remote Sensing, IEEE Transactions on, v.33, n.2, p.293-304, 1995.

BARNES, M.;DUCKETT, T.;CIELNIAK, G.;STROUD, G. HARPER, G. **Visual detection of blemishes in potatoes using minimalist boosted classifiers.** Journal of Food Engineering, v.98, n.3, p.339-346, 2010.

BENNEDSEN, B. S.;PETERSON, D. L. TABB, A. **Identifying defects in images of rotating apples.** Computers and Electronics in Agriculture, v.48, n.2, p.92-102, 2005.

BISHOP, C. M. **Neural Networks for Pattern Recognition.** Clarendon Press, Oxford, 1995.

BLASCO, J.;ALEIXOS, N. MOLTÓ, E. **Computer vision detection of peel defects in citrus by means of a region oriented segmentation algorithm.** Journal of Food Engineering, v.81, n.3, p.535-543, 2007.

BLASCO, J.;CUBERO, S.;GÓMEZ-SANCHÍS, J.;MIRA, P. MOLTÓ, E. **Development of a machine for the automatic sorting of pomegranate (*Punica granatum*) arils based on computer vision.** Journal of Food Engineering, v.90, n.1, p.27-34, 2009.

BRAGA, A. P., CARVALHO, A. C. P. L. F., LUDERMIR, T. B., **Redes Neurais Artificiais: teoria e aplicações.** Editora LTC, 2000.

BROSNAN, T. SUN, D.-W. **Inspection and grading of agricultural and food products by computer vision systems-a review.** Computers and Electronics in Agriculture, v.36, n.2-3, p.193-213, 2002.

BROSNAN, T. SUN, D.-W. **Improving quality inspection of food products by computer vision—a review.** Journal of Food Engineering, v.61, n.1, p.3-16, 2004.

CASTANÕN, C. A. B. **Recuperação de Imagens por Conteúdo através de Análise Multiresolução por Wavelets.** 2003. Dissertação ((Mestrado em Ciências da Computação e Matemática Computacional) – Universidade de São Paulo. 94p.

CEAGESP. Programa brasileiro para a melhoria dos padrões comerciais e embalagens de hortifrutigranjeiros: Classificação da cenoura: programa de adesão voluntária. CEAGESP: *Centro de qualidade em horticultura*, São Paulo, 2000.

CHALIDABHONGSE, T.;YIMYAM, P. SIRISOMBOON, P. **2D/3D Vision-Based Mango's Feature Extraction and Sorting.** Control, Automation, Robotics and Vision, 2006. ICARCV '06. 9th International Conference on. 5-8 Dec. 2006, p.1-6, 2006.

CHANG, T.; KUO, C.-C. J. A wavelet transform approach to texture analysis. IEEE International Conference on Acoustics, Speech, and Signal Processing, v. 4, p. 661–664, mar. 1992.

CONGALTON, R. G. **A review of assessing the accuracy of classifications of remotely sensed data.** Remote Sensing of Environment, v.37, n.1, p.35-46, 1991.

DAVIES, E. R. **The application of machine vision to food and agriculture: a review.** Imaging Science Journal, The, v.57, p.197-217, 2009.

DU, C.-J. SUN, D.-W. **Learning techniques used in computer vision for food quality evaluation: a review.** Journal of Food Engineering, v.72, n.1, p.39-55, 2006.

GONZALEZ, R.C.; WOODS, R.E. **Processamento de imagens digitais.** São Paulo: Editora Edgard Blücher Ltda, 2000, 509p.

GUNASEKARAN, S. **Computer vision technology for food quality assurance.** Trends in Food Science & Technology, v.7, n.8, p.245-256, 1996.

HAYKIN, S.; **Redes Neurais: Princípios e Prática.** Tradução: Engel, P.M.; Bookman, 2ª Ed.; Porto Alegre, 2001.

HU, B. G.;GOSINE, R. G.;CAO, L. X. DE SILVA, C. W. **Application of a fuzzy classification technique in computer grading of fish products.** Fuzzy Systems, IEEE Transactions on, v.6, n.1, p.144-152, 1998.

JAHNS, G.;MØLLER NIELSEN, H. PAUL, W. **Measuring image analysis attributes and modelling fuzzy consumer aspects for tomato quality grading.** Computers and Electronics in Agriculture, v.31, n.1, p.17-29, 2001.

JEYAMKONDAN, S.; KRANZLER, G. A., LAKSHMIKANTH, A. **Predicting Beef Tenderness with Computer Vision.** ASAE Annual International Meeting Sponsored by ASAE Sacramento Convention Center Sacramento, California, USA July 30-August 1, 2001.

KONG, X.;LUO, Q.;ZENG, G. LEE, M. H. **A new shape descriptor based on centroid-radii model and wavelet transform.** Optics Communications, v.273, n.2, p.362-366, 2007.

LATIF-AMET, A.;ERTÜZÜN, A. ERÇIL, A. **An efficient method for texture defect detection: sub-band domain co-occurrence matrices.** Image and Vision Computing, v.18, n.6-7, p.543-553, 2000.

LEE, D.J. ; XU, X.; LANE, R.M. ; ZHAN, P. **Shape Analysis for an Automatic Oyster Grading System,** SPIE Optics East,Two and Three-Dimensional Vision Systems for Inspection, Control, and Metrology II, vol. 5606-05, Philadelphia, PA,USA, p. 25-28, 2004.

LEEMANS, V.;MAGEIN, H. DESTAIN, M. F. **Defect segmentation on ['Jonagold' apples using colour vision and a Bayesian classification method.** Computers and Electronics in Agriculture, v.23, n.1, p.43-53, 1999.

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

MALLAT, S. G. **A theory for multiresolution signal decomposition: the wavelet representation.** Pattern Analysis and Machine Intelligence, IEEE Transactions on, v.11, n.7, p.674-693, 1989.

MENDOZA, F. AGUILERA, J. M. **Application of Image Analysis for Classification of Ripening Bananas.** Journal of Food Science, v.69, n.9, p.E471-E477, 2004.

MISITI, M. y.; OPPENHEIM, G.; POGGI, J. **Wavelet toolbox for use with MATLAB - User's Guide. USA; The Mathworks, Inc., Version 1, 1996-1997.**

MOKJI, M. M. ABU BAKAR, S. A. R. **Gray Level Co-Occurrence Matrix Computation Based On Haar Wavelet.** Computer Graphics, Imaging and Visualisation, 2007. CGIV '07. 14-17 Aug. 2007, p. 273-279, 2007.

MURAYAMA, S. **Horticultura.** Campinas: Instituto Campineiro de Ensino Agrícola, 1983. 321p. il.

NOORDAM, J. C.; OTTEN, G. W.; TIMMERMANS, T. J. M. ZWOL, B. H. V. **High-speed potato grading and quality inspection based on a color vision system: SPIE,** p. 206-217, 2000.

OLIVEIRA, O. R. F.; PALOMO, D. M. **Utilização de wavelets na multirresolução de imagens.** Disponível em: <http://www.dpi.inpe.br/~danilo/pessoal/trabalhos/Terrawavelets_PDI.pdf>. Acesso em: Mai, 2010.

OTSU, N. **A Threshold Selection Method from Gray-level Histograms.** IEEE Transactions on Systems, Man and Cybernetics, V.9, n.1, p.62-66, 1979.

PAULUS, I.; DE BUSSCHER, R. SCHREVEN, E. **Use of Image Analysis to Investigate Human Quality Classification of Apples.** Journal of Agricultural Engineering Research, v.68, n.4, p.341-353, 1997.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de imagens digitais: princípios, algoritmos e aplicações.** São Paulo: Thomson Learning, 508 p., 2008.

PETROU, M.; SEVILLA, P. G. **Image processing: Dealing with texture**. New York: Wiley , 618 p. 2006.

PUN, T.;LEFEBVRE, M.;GIL, S.;BRUNET, D.;DESSIMOZ, J.-D. GUEGERLI, P. **Potato operation: computer vision for agricultural robotics: SPIE**, p.320-331, 1992.

ROSENFELD, G. H.; FITZPATRICK-LINS, K. **A coefficient of agreement as a measure of thematic classification accuracy**. Photogrammetric engineering & remote sensing. Bethesda, v.52 n.2, p.223-227,1986.

SARKAR, N.; WOLFE, R. R. Computer vision based system for quality separator of fresh-market tomatoes. **Transactions of the ASAE**, St. Joseph, v. 28, n. 5, p. 1714-1718, 1985.

SHAHIN, M. A.;TOLLNER, E. W. MCCLENDON, R. W. **AE--Automation and Emerging Technologies: Artificial Intelligence Classifiers for sorting Apples based on Watercore**. Journal of Agricultural Engineering Research, v.79, n.3, p.265-274, 2001.

SIMÕES, A. S.; COSTA, A. H. R. **Classificação de laranjas baseada em padrões visuais**. In: VI Simpósio Brasileiro de Automação Inteligente. Sociedade Brasileira de Automática - SBA. CDROM.14-17, p. 77-81, 2003.

SIÉLER, L.;TANOUGAST, C. BOURIDANE, A. **A scalable and embedded FPGA architecture for efficient computation of grey level co-occurrence matrices and Haralick textures features**. Microprocessors and Microsystems, v.34, n.1, p.14-24, 2010.

SUN, D.-W. DA-WEN, S. Preface. In: (Ed.). **Computer Vision Technology for Food Quality Evaluation**. Amsterdam: Academic Press. Preface, p.xv-xv, 2008.

The MathWorks, Wavelet Toolbox for user with Matlab, version 3, 2005.

THROOP, J. A.;ANESHANSLEY, D. J.;ANGER, W. C. PETERSON, D. L. **Quality evaluation of apples based on surface defects: development of an automated inspection system**. Postharvest Biology and Technology, v.36, n.3, p.281-290, 2005.

ZHENG, C.;SUN, D.-W. DA-WEN, S. Image Segmentation Techniques. In: (Ed.). **Computer Vision Technology for Food Quality Evaluation**. Amsterdam: Academic Press, Image Segmentation Techniques, p.37-56, 2008.

ZION, B.;SHKLYAR, A. KARPLUS, I. **Sorting fish by computer vision.**
Computers and Electronics in Agriculture, v.23, n.3, p.175-187,1999.

CAPÍTULO 5 SISTEMA PARA AQUISIÇÃO DE IMAGENS UTILIZANDO CAMERA LINE-SCAN

5.1 INTRODUÇÃO

A maior conscientização e sofisticação na escolha de produtos hortigranjeiros por parte dos consumidores criaram a expectativa de melhoria de qualidade destes produtos oferecidos pelos produtores rurais. Este fato resultou no aumento da necessidade de monitoramento da qualidade dos produtos, onde qualidade pode ser definida como a soma de todos os atributos que levam à aceitação de um produto por parte do consumidor. A avaliação de qualidade é subjetiva, levando-se em conta a aparência, aroma, textura e sabor. Esta avaliação da qualidade resulta em montagem de linhas de classificação e separação de produtos, normalmente compostas por examinadores humanos, realizando manualmente o trabalho.

Esta separação e classificação podem ser realizadas manualmente ou por sistemas automáticos. Os sistemas manuais são tediosos, trabalhosos, inconsistentes e demorados e, além disto, são subjetivos, pois cada profissional envolvido no processo pode analisar de forma diferente um mesmo produto, classificando-o em categorias diferentes (GUNASEKARAN,1996).

Para suprir estes problemas, pesquisas recentes têm sido desenvolvidas utilizando sistemas de processamento digital de imagens para realizar processos de inspeção e classificação de produtos. Os sistemas de visão artificial (SVA) apresentam uma flexibilidade de recursos, como velocidade de operação, uniformidade e redução de custos, além de substituir o trabalho humano nas tarefas que são subjetivas, inconsistentes, cansativas, monótonas e desgastantes (BROSNAN & SUN, 2002).

Os SVAs são constituídos de sistemas de captura, processamento e análise de imagens, facilitando a avaliação objetiva e não-destrutiva das características de qualidade visual dos produtos alimentares. Os recentes avanços em hardware e software têm auxiliado nessa expansão, fornecendo

soluções de baixo custo, e incentivando as pesquisas nesta área. Estes sistemas oferecem baixa relação custo/benefício, repetibilidade, velocidade de processamento e precisão superior em relação aos sistemas manuais.

Um ponto crítico dos SVAs é a etapa de aquisição das imagens, pois este sub-sistema deve atuar com altas taxas de transferência de dados e permitir flexibilidade de uso, devido à variação dos formatos existentes em um determinado produto agrícola. As câmeras utilizadas devem ter taxas de aquisição de imagens e correções para minimizar ruídos que sejam compatíveis com a aplicação proposta. As câmeras do tipo line-scan apresentam características de alta taxa de aquisição e transferência de dados, mas apresentam o inconveniente de adquirir somente uma linha de imagem por vez e dificuldade no ajuste dos parâmetros. O objeto deve então estar em movimento para ser completamente imageado pela câmera.

Neste trabalho, foi proposto a utilização de câmeras line-scan para adquirir imagens de raízes de cenouras em movimento, sejam estas dispostas em esteiras ou com imagens adquiridas durante a passagem de uma esteira para outra. Foram desenvolvidas metodologias para serem efetuados o ajuste de foco e dos parâmetros da câmera, e calculada qual a taxa de aquisição indicada para o sistema. Foi também avaliada a capacidade do sistema de capturar imagens de todo o contorno das raízes através da utilização de espelhos, de modo a ser implementado de um sistema automático de separação e classificação de raízes de cenouras.

5.2 FUNDAMENTAÇÃO TEÓRICA

Os SVAs têm sido utilizados na classificação de diversos produtos agrícolas. No caso de frutos, merecem destaques os trabalhos com cítricos e maçãs, devido ao valor econômico destes produtos em alguns países. Nos cítricos, normalmente são avaliados os defeitos externos e a coloração dos frutos (KONDO et al.,2000; SIMÕES,2003; BLASCO et al,2007) ou a identificação de danos internos, causados por doenças ou congelamento (GAMBHIR et al., 2004). Quanto a maçãs, existem trabalhos desenvolvidos para detecção dos defeitos externos (LEEMANS & DESTAIN, 2004;

BENNEDSEN et al.; 2005) e detecção do cálice e do pendúnculo (CHENG et al., 2003; UNAY & GOSELIN, 2007). Na área de olericultura, Jahns et al. (2001) e Louro (2006) apresentaram trabalho sobre separação de tomates utilizando SVAs.

Os SVAs são tipicamente compostos por um sistema de iluminação, um microcomputador, uma placa de aquisição de imagens (*frame grabber*) e uma câmera digital. Os *frame grabbers* são utilizados para interfacear a câmera com o microcomputador, e realizam tarefas de armazenagem e pré-processamento dos dados. Utilizando padrões de comunicação dedicados, os *frame grabbers* atingem altas taxas de transferência de dados utilizando padrões, como o *CameraLink 2000*, com velocidade máxima 1923 Gb/s.

As câmeras digitais são constituídas por um dispositivo fotossensível, sendo disponíveis duas tecnologias: o *Complementary Metal Oxide Semiconductor* (CMOS) ou o *Charged Coupled Device* (CCD), sendo que ambos transformam a luz refletida para sinais elétricos. Estes sinais elétricos passam por um conversor analógico-digital, obtendo como saída a representação da imagem de um objeto qualquer.

Quanto ao formato do sensor, as câmeras digitais podem ser divididas em dois grupos: *area scan* e *line-scan*. As câmeras do tipo *área scan* utilizam CCD's bi-dimensionais, formando uma matriz NxM de pixels, tais como 640x480, 1024x1024, 1600x1200 e outras. Nestas câmeras, a imagem é adquirida de uma só vez, ou seja, todos os NxM pixels são simultaneamente sensibilizados pela luz e transmitidos para a saída.

Os CCD utilizados nas câmeras *line-scan* possuem apenas uma linha de pixels, e funcionam de maneira semelhante aos aparelhos de fax e scanners, realizando a aquisição da imagem linha por linha, até formar a imagem inteira. A figura 1 apresenta uma comparação entre os dois tipos de CCD's.

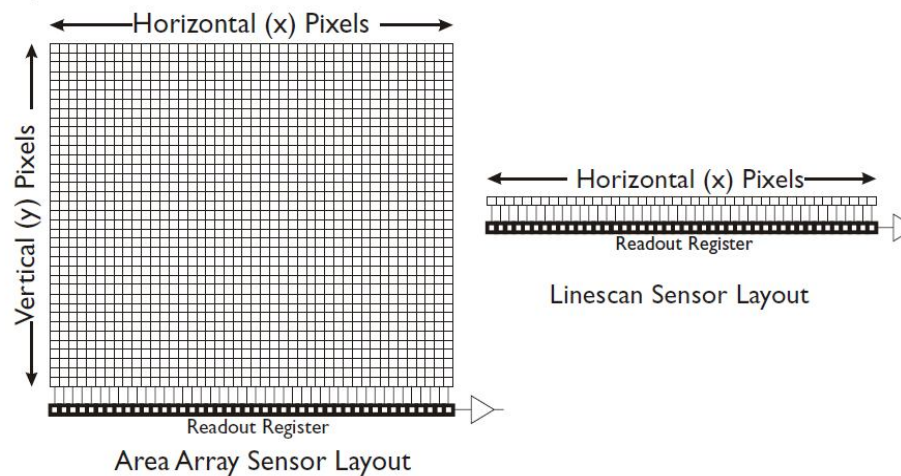


Figura 1. Comparação entre o layout dos sensores (CCD's) utilizados nas câmeras *area scan* e *line-scan* (DALSA, 2010).

As câmeras *line-scan* têm a vantagem de oferecerem altas taxas de aquisição e transmissão de dados, além de permitirem combinações quanto a uma das dimensões da imagem. São indicadas principalmente para o uso na inspeção em linhas de produção de altas velocidades, como inspeção de tábuas e na fabricação de tecidos, e em outras aplicações que exijam grandes taxas de aquisição de imagens. Outra vantagem da *line-scan* é a possibilidade de se ajustar e controlar a intensidade luminosa necessária apenas na pequena faixa de aquisição do CCD, ao contrário das câmeras *line-scan*, onde todo o objeto deve ser uniformemente iluminado (GHITA et al., 2005).

A utilização das câmeras *line-scan* nos processos de inspeção pode ser comprovada nos trabalhos de Chao et al. (2007), que utilizaram este tipo de câmera para detectar defeitos em carcaças de frangos abatidos, em uma linha com velocidade de 70 animais por minuto; e de Kline et al (2003) que utilizaram a câmera associada a um equipamento laser e de raio-X para detectar defeitos em tabuas de madeira, atingindo velocidades de 0,6 m/s.

Kim et al. (2007) utilizaram câmeras *line-scan* hiperespectrais, nas bandas do visível e do infravermelho próximo (NIR). A utilização da banda do infravermelho próximo permitiu ao sistema a detecção de contaminações fecais ocorridas em maçãs. Testes preliminares efetuados pelos autores atingiram a

capacidade de inspeção de 50 maçãs por segundo, utilizando um computador com processador de 2 GHz.

Um ponto crítico da utilização das câmeras *line-scan* é a sincronização da velocidade do objeto com a taxa de aquisição da imagem, pois na falta de sincronismo, a imagem obtida pode sofrer distorções. Uma das maneiras de realizar este sincronismo é a aplicação de um pulso de disparo (*trigger*), que inicia a aquisição de uma linha da imagem. Após este pulso, o CCD é sensibilizado pela luz refletida pelo objeto, e a informação obtida é então repassada a um dispositivo de memória denominado registro de leitura. Como o CCD lê apenas uma única linha de pixels por exposição, as câmeras *line-scan* requerem muito menos tempo para transferir as informações do CCD para o registro de leitura, e deste para a saída da câmera.

Outra característica que acelera o processo de aquisição da imagem é o fato de que, enquanto ocorre a transferência da informação contida no registro de leitura para a saída da câmera, um novo pulso de disparo é aplicado. Desta forma, a câmera realiza a aquisição de uma nova linha da imagem simultaneamente ao processo de transferência dos dados obtidos durante o pulso de disparo anterior.

Se os produtos são dispostos em uma esteira rolante, o pulso de disparo pode ser fornecido por um sensor externo (*encoder*) ligado à esteira, sincronizando a velocidade desta com a aquisição da imagem. O *encoder* é utilizado principalmente nos processos de inspeção denominados de *web inspection*, onde um material é produzido continuamente, como tubos, tecidos, plásticos e outros.

A utilização de SVAs em linhas de separação de produtos utilizando câmeras *line-scan* pode atingir altas taxas de velocidade na classificação de produtos, pois a rapidez na aquisição e transferência da imagem cumpre os requisitos para desenvolver aplicações de classificação em tempo real.

Operação da câmera line-scan

Como disposto anteriormente, as câmeras *line-scan* são mais complexas do que as do tipo *area scan*, sendo necessário realizar a configuração e ajuste da câmera para adquirir imagens. Dentre estas configurações, estão o tempo de exposição, o tamanho da imagem, e outras configurações, de acordo com o modelo de câmera utilizado.

A figura 2 apresenta uma janela do software CamExpert, disponibilizado para configuração dos parâmetros da câmera Dalsa PC-30-02K80-00-R, apresentando o sincronismo entre *trigger*, a geração do sinal de leitura (*readout*) e o tempo de exposição (exposure) dos CCD's.

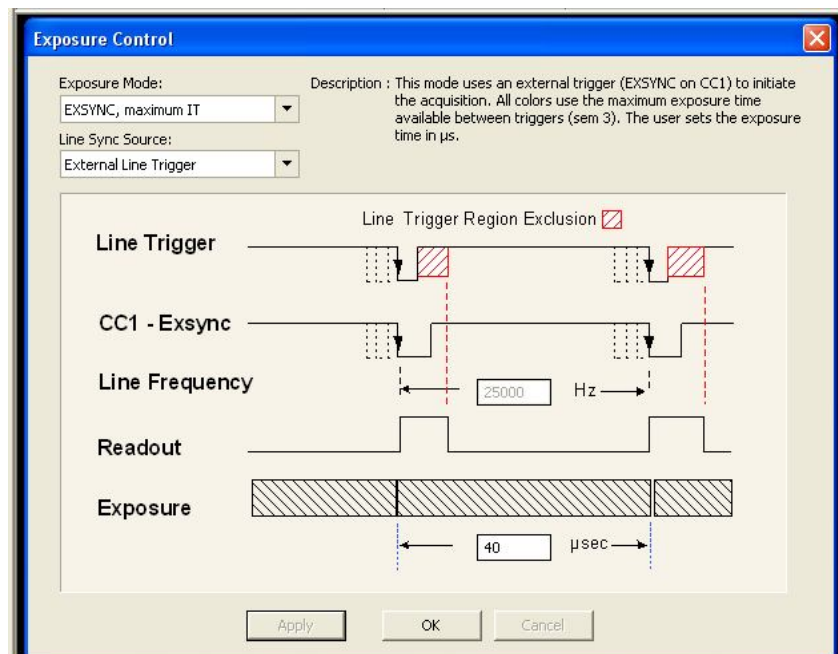


Figura 2. Janela do software CamExpert apresentando a sincronização entre o pulso de disparo (*trigger*) com a aquisição de dados (*readout*).

Nos casos em que não é possível sincronizar a velocidade do objeto com a taxa de aquisição da câmera, pode ser utilizado um gerador de pulsos síncronos presente internamente no circuito da câmera, que determina uma temporização fixa para a aquisição das imagens, independente da

movimentação do objeto. A taxa de aquisição da câmera deve então ser ajustada de acordo com a velocidade do objeto.

Na figura 3 é apresentado o diagrama de tempo de um sinal periódico, gerado internamente, que determina o tempo de exposição de cada CCD. Neste exemplo, a câmera utilizada possui três CCD's, um para cada cor básica. O tempo de exposição de cada CCD pode ser determinado individualmente, permitindo que cada um deles possa ficar ativo por um tempo maior ou menor do que o outro, o que possibilita em um melhor ajuste da imagem.

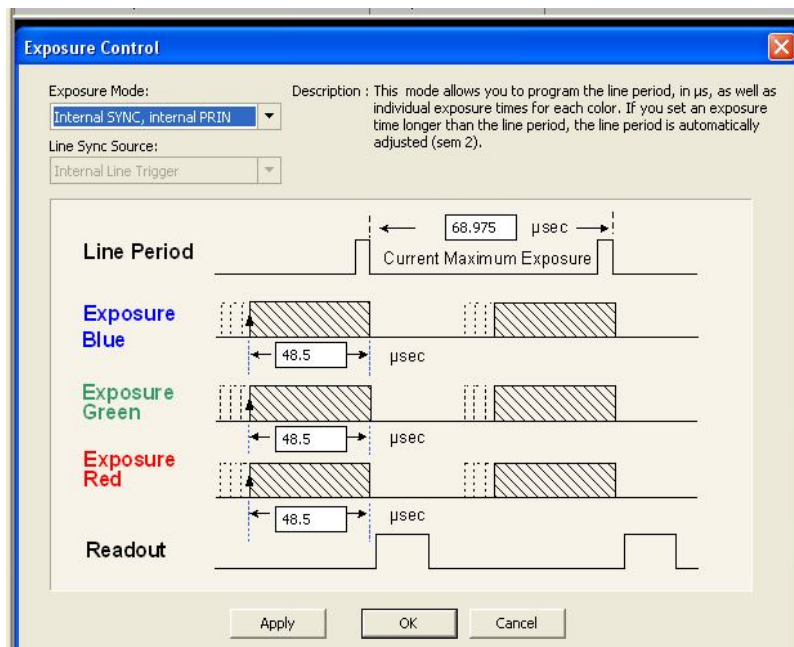


Figura 3. Janela do software CamExpert apresentando a interação interna de um pulso de disparo com a aquisição de dados.

A taxa de aquisição ($T_{x_{aq}}$) é dependente velocidade média do objeto (vel_m) e da resolução espacial desejada (r_{des}). A taxa de aquisição é calculada utilizando a equação 1.

$$T_{x_{aq}} = \frac{vel_m}{r_{des}} \quad (1)$$

As câmeras *line-scan* possuem diversos recursos para compensar problemas de iluminação e de ruídos na imagem. Um destes recursos é a possibilidade de calcular a correção de coeficientes que são aplicados ao sinal

analogico de forma a compensar a não uniformidade da imagem. Estas correções são efetuadas pixel-a-pixel, reduzindo ou eliminando as distorções durante a aquisição da imagem.

Na figura 4 é apresentado o diagrama de blocos simplificado do processamento do ganho analógico e digital da câmera. No primeiro sub-bloco é realizado o processamento analógico, onde pode ser aplicado um ganho (SAG) e depois um offset (SAO) no sinal de entrada analógico (An_in). No sub-bloco da parte digital são realizadas diversas operações, como a correção da não linearidade da resposta da iluminação através da utilização de *look-up table* (LUT), a correção do padrão de ruído fixo (FPN), a correção da não uniformidade aleatória dos pixels (PRNU), e a adição e remoção de fundo e ganho digital.

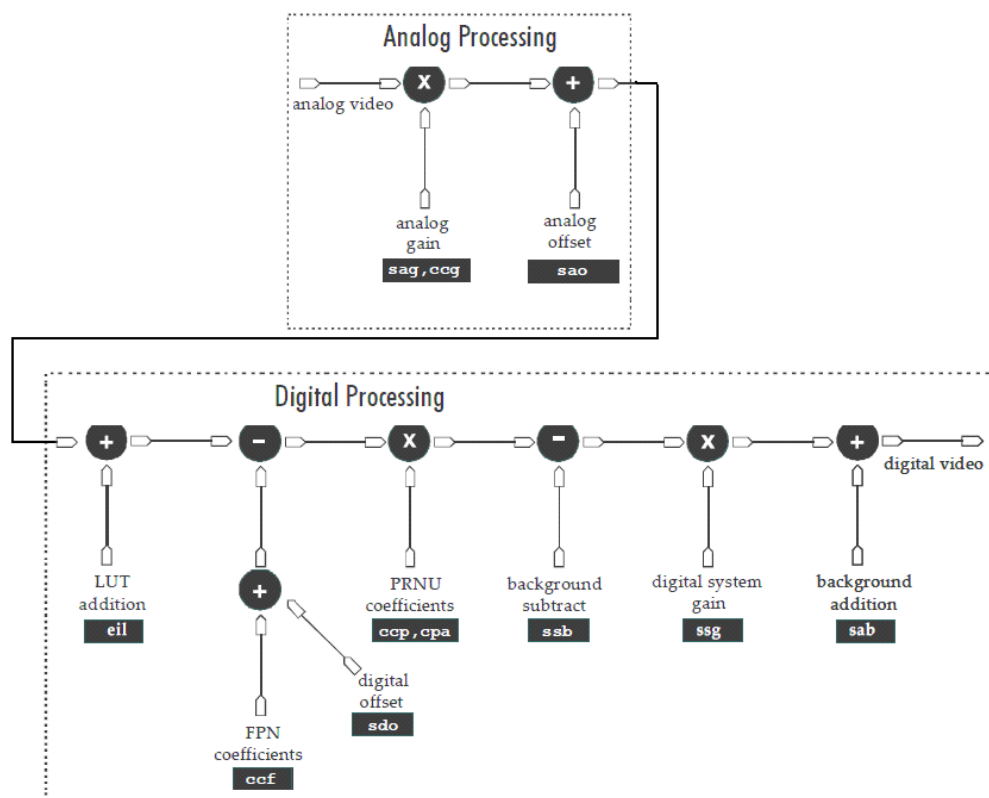


Figura 4. Diagrama em blocos dos coeficientes de ajustes da câmera Dalsa PC-30-02K80-00-R (DALSA, 2008).

O padrão de ruído fixo (calibração FPN) é usado para subtrair pixels escuros que ocorreram durante a calibração realizada utilizando uma placa padrão na cor branca. A correção PRNU é utilizada para corrigir individualmente a diferença da resposta de cada pixel seja provocada por aberrações óticas ou por diferença de iluminação, garantindo que todos os pixels não saturar junto. O *offset digital* (SDO) permite a alteração do offset do conversor A/D de modo que a aplicação do coeficiente PRNU não resulte em níveis de pixels escuros.

A subtração (SSB) e o ganho digital (SSG) são usados para incrementar o contraste da imagem depois da calibração FPN e PRNU. Por exemplo, se a imagem apresenta valores entre 128 e 255, em uma escala de 0 a 255, pode ser subtraído um offset de 128 e aplicado um ganho de 2x, alterando a faixa de valores para 0 a 255. A adição de *background* (SAB) é usada para assegurar um valor mínimo na saída, e é aplicado ao sinal digital de vídeo depois que o ganho é aplicado. A saída de vídeo final depois de aplicado todos estes recursos é obtida utilizando a equação 2.

$$Dig_out = (([Analog_in]SAG + SAO - SDO - FPN).PRNU - SSB).SSG + SAB \quad (2)$$

5.3 MATERIAL E MÉTODOS.

O experimento foi conduzido no laboratório PROVISAGRO, da Universidade Federal de Viçosa. Para aquisição das imagens, foi utilizada uma câmera PC-30-02K-80 e o frame grabber X64-Express, ambos da Dalsa Corporation, e a lente AF-S NIKKOR, de distância focal variável de 18 a 70mm. O sistema de iluminação foi composto de 8 lâmpadas fluorescentes PHILIPS TL-D90, com temperatura de cor de 6500K, dispostas em uma caixa de madeira recoberta de fórmica cinza fosco. Para diminuir o efeito de cintilação (*flickering*) causado pelas lâmpadas e melhorar o espalhamento da luz, as lâmpadas foram cobertas com uma placa de poliestireno branco fosco. A montagem do sistema foi conforme figura 5.




Figura 5. Esquema da vista superior do sistema de aquisição de imagens de cenouras em queda livre.

Para o cálculo da taxa de aquisição, foi utilizada a equação 1, considerando:

Largura da imagem:	45 cm;
Resolução da câmera:	2048 pixels
Velocidade média durante a queda:	3 m/s.

$$Tx_{aq} = \frac{3m/s}{(0,45m/2048)} = 13653Hz \quad (3)$$

Para configuração dos parâmetros e calibração da câmera, foi utilizado o software CamExpert, disponibilizado com a câmera.

Inicialmente foi ajustado o foco do sistema. Como a câmera adquire somente uma linha por vez, não é possível direcionar a câmera para um objeto

e ajustar manualmente o foco da lente. Para solucionar este problema, foi utilizada uma folha impressa com linhas paralelas separadas por 5 mm, disposta a 45 cm da câmera, de tal forma que qualquer linha adquirida pela câmera fosse repetida, criando uma imagem de linhas paralelas. Para adquirir esta imagem, a câmera foi ajustada para a taxa de aquisição de 13653 Hz, e a imagem ajustada para 2048x3000 pixels. A câmera foi mantida imóvel, montada sobre um tripé.

A partir desta imagem, foi realizado o ajuste manual do foco para se obter a melhor definição da imagem.

Após o ajuste de foco, foi efetuada a calibração da câmera, para ajuste dos coeficientes de correção de ajuste de branco, não-linearidade e ruídos. Durante o processo de calibração, utilizou-se um objeto como referência de cor branca e um de cor negra. Para a referência padrão de cor branca foi utilizada uma placa de madeira MDF na cor branco-fosco, e para a cor negra, a lente da câmera foi coberta, conforme descrito pelo manual da câmera.

Para aquisição das imagens, foi desenvolvido um programa utilizando a linguagem C. O programa reinicializava a câmera e aguardava que fosse pressionada qualquer tecla do computador. Para este trabalho, a resolução da imagem adquirida foi mantida em 2048x4000 pixels. O operador soltava uma raiz de cenoura e pressionava uma tecla do computador para capturar a imagem.

Para se obter o tempo consumido para a aquisição da imagem e transferência da imagem para o computador, foi desenvolvida uma rotina no programa que totaliza o número de pulsos de *clock* do computador e o transforma em segundos. Foi realizada a aquisição de imagens de 20 raízes, com diâmetros e comprimentos diversos.

Para aquisição das faces laterais das raízes, foram utilizados espelhos comerciais, sem nenhum tratamento especial. Os espelhos foram dispostos em um sistema móvel, permitindo ajustar o ângulo para aquisição das imagens. Foram testadas a refração das imagens de raízes com diferentes diâmetros,

todas posicionadas a uma distância de 5 cm do eixo perpendicular dos espelhos.

Para verificar se a imagem adquirida representa todo o contorno das raízes, foram realizados testes com duas raízes, com o menor e maior diâmetro disponível entre as amostras. Para exibição da imagem do contorno das raízes, a câmera PC-30 foi substituída por uma câmera de uso comercial modelo SONY DSC-X1. Um papel numerado de 1 a 25 foi fixado nas raízes e foram tomadas as imagens, com o foco ajustado para as imagens refletidas nos espelhos.

5.4 RESULTADOS E DISCUSSÃO

O foco da lente foi ajustado manualmente para se obter a melhor definição da imagem, conforme metodologia proposta. Na figura 6 é apresentada a imagem obtida.

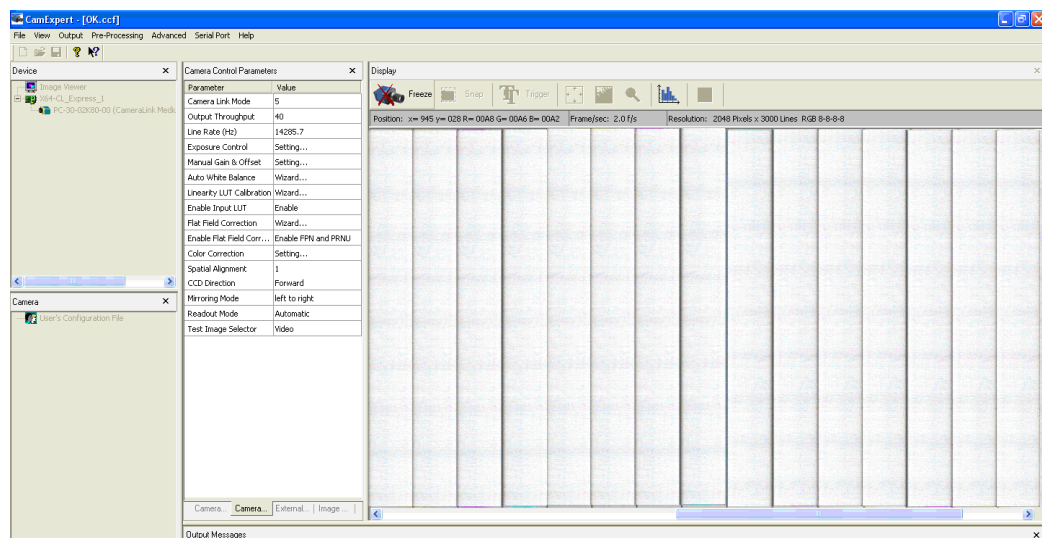


Figura 6. Janela do software CamExpert para ajuste de foco manual da câmera utilizando uma papel impresso com linhas verticais.

A figura 7 apresenta uma imagem capturada de uma embalagem de um produto, com preenchimento para simular o peso de uma raiz de cenoura. Nesta figura, pode-se confirmar visualmente que o ajuste de foco foi realizado corretamente.


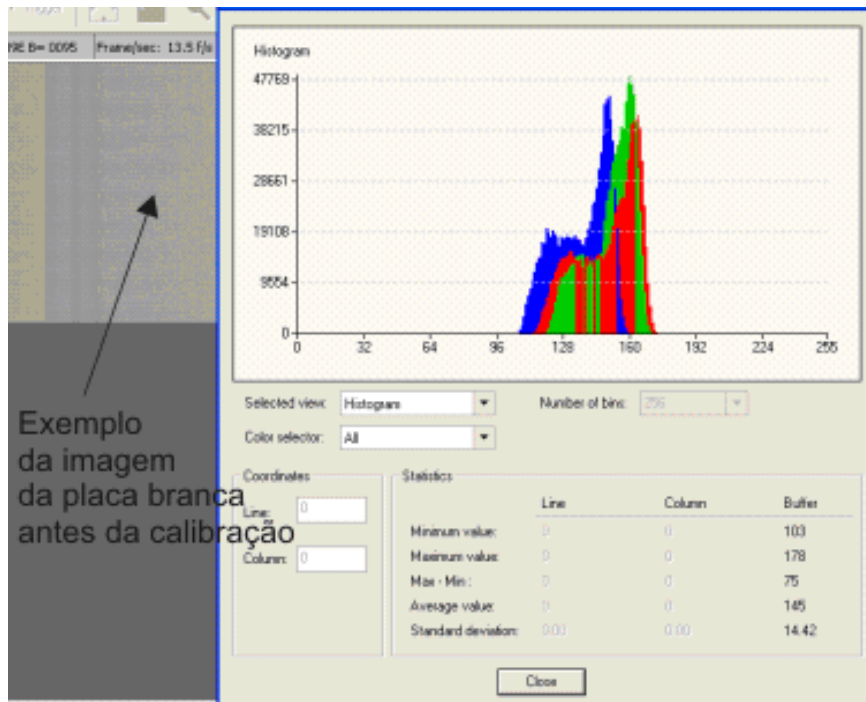
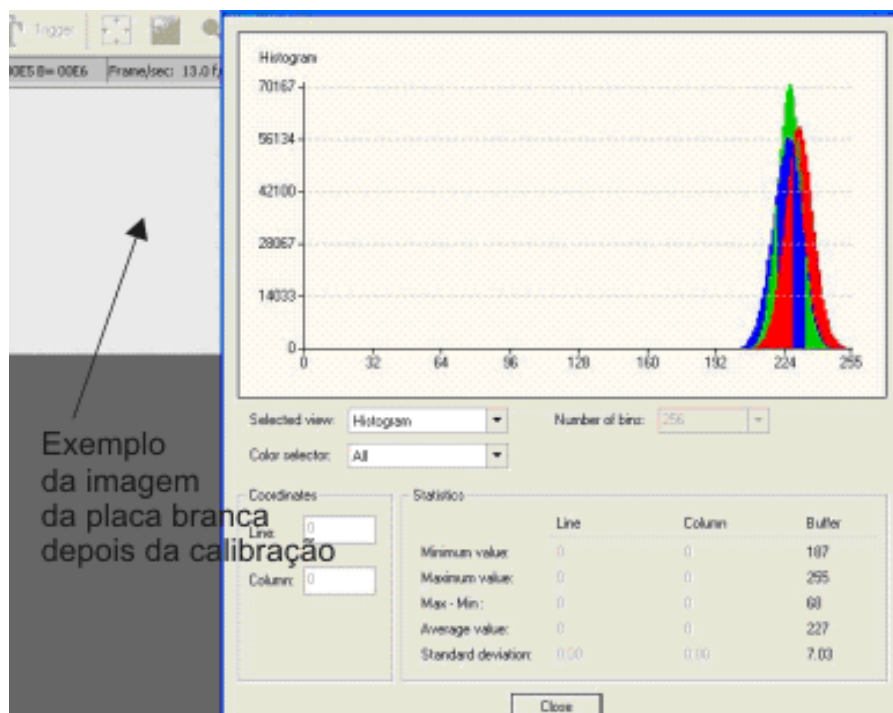


Figura 7. Imagem capturada após ajuste de foco manual, apresentando boa definição dos detalhes do objeto.

Na figura 8 é apresentada uma amostra da imagem obtida na placa branca e o histograma da imagem antes e depois da calibração. Na figura 8(a) a imagem capturada da placa branca apresenta um histograma distorcido, apresentando valores de pixels distribuídos em uma larga faixa de valores. A imagem obtida com esta configuração resulta em uma figura com diferentes tonalidades. Após a calibração, onde foram ajustados os coeficientes LTU, PRNU e PNU, o histograma foi corrigido, como apresentado na figura 8(b), apresentando uma concentração maior dos pixels próximos ao valor do branco. A figura da placa branca obtida após a calibração apresenta uma imagem sem distorções nas cores, indicando a correta calibração dos parâmetros de correção de cores.



(a)



(b)

Figura 8. Calibração para ajuste de branco e correção de ruídos (a) antes e (b) depois da calibração.

O tempo médio de aquisição das imagens foi de de 16 ms, consumidos no processo de aquisição e transferência para a memória do computador,

indicando assim a possibilidade de adquirir até 62 imagens por segundo. Na figura 9 é apresentada uma imagem obtida utilizando o sistema proposto.



Figura 9. Exemplo de imagem adquirida com o sistema desenvolvido.

Na figura 9, observa-se a distorção provocada pelo sistema de espelhos utilizados. A imagem central, capturada diretamente da cenoura, se apresenta nítida, mas as imagens laterais apresentaram problemas de distorção, provocados pela falta de equidistanciamento da cenoura entre os dois espelhos. Outro problema encontrado foi a queda inclinada da raiz, provocando a aproximação de uma das pontas ao espelho e conseqüentemente o distanciamento da outra. Para solucionar estes problemas, poderia ser implementado um duto de condução, de forma a alinhar a raiz perpendicularmente com o eixo de captura do CCD. Outra melhoria seria a utilização de espelhos com um grau de aumento, e implementar uma correção das imagens capturadas. Esta correção pode ser realizada aplicando um fator de escala nas imagens do espelho, que é obtido pela razão entre o comprimento da raiz na imagem principal (C_{ip}) e comprimento da raiz na imagem do espelho (C_{ie}), conforme equação 4.

$$F_{escala} = \frac{C_{ip}}{C_{ie}} \quad (4)$$

Na figura 10 são apresentadas as imagens obtidas pelo sistema de espelhos proposto, utilizando uma raiz de 3cm de diâmetro e a câmera SONY DSC-X1, exibindo o contorno da raiz.



Figura 10. Imagens de uma raiz 3 cm de diâmetro. A imagem central foi capturada diretamente da raiz e as imagens à esquerda e à direita são reflexos do espelho.

Analisando visualmente as imagens, percebe-se que há uma distorção nas bordas externas das mesmas, devido à forma circular das raízes. Uma solução para este problema seria a utilização de espelhos parabólicos que permitiriam circundar as raízes e obter imagens sem estas distorções, conforme descrito por Reese et al. (2009).

Neste trabalho, foi utilizada apenas uma linha de alimentação, utilizando uma câmera de 2048 pixels. Caso seja adotada uma câmera de 4096 pixels ou superior, pode-se adquirir imagens simultâneas de 3 ou mais linhas de produção, melhorando ainda mais a performance do sistema.

O sistema de iluminação utilizado foi de baixo custo, utilizando lâmpadas comuns adquiridas no varejo, e apresentou problemas durante a calibração da câmera devido à frequência de 42 kHz gerada pelos reatores que acionam a lâmpadas, que ocasionam o fenômeno de *flickering*. Este fenômeno provoca a alternância entre a presença ou não de eletricidade nas lâmpadas, provocando flutuações na iluminação. Porém, este fenômeno não interferiu significativamente na captura das imagens. Uma solução seria alimentar as lâmpadas com um sistema trifásico, com cada lâmpada ligada a uma fase diferente, o que reduziria o intervalo de *flickering* entre elas, ou utilizar projetores utilizando diodos emissores de luz de cor branca.

O uso de um sistema de queda livre para aquisição da imagem foi montado apenas para testes de aquisição, pois tem o problema de ocasionar danos mecânicos nas raízes. O sistema de transporte recomendado é o de utilização de três esteiras alimentadoras, E_1 , E_2 e E_3 , de tal forma que tenham velocidades $V_1 < V_2 < V_3$. Uma quarta esteira é disposta afastada da terceira, e a câmera seria disposta entre a terceira e quarta esteira. A primeira esteira alimenta o sistema de aquisição de imagens, onde são descarregados os engradados contendo as raízes. A segunda esteira, que tem uma velocidade de rotação maior do que a primeira, impulsiona as raízes, aumentando a distância entre as raízes dispostas na esteira. A terceira esteira, com velocidade muito maior do que a segunda, impulsiona as raízes para ganharem velocidade de tal forma que possam ser lançadas através da câmera e caiam na quarta esteira, para posterior separação utilizando um sistema mecanizado. Um sistema ótico acoplado à terceira esteira permitiria gerar um pulso de disparo sincronizado, permitindo melhorias na aquisição da imagem.

As imagens obtidas pelos espelhos, apresentada na figura 9, se mostraram distorcidas e com o efeito de *flickering* devido à reflexão das lâmpadas diretamente no espelho, não oferecendo a mesma nitidez da imagem obtida diretamente da raiz, apresentada na parte central desta figura. Alguns trabalhos como o de Reese et al. (2009) apresentam soluções utilizando espelhos parabólicos e com um grau de magnificação, permitindo assim imagens mais nítidas e mais reais dos objetos.

Uma opção para melhorar ainda mais a desempenho do sistema seria a utilização de sistemas em cascatas, sendo que o primeiro sistema poderia separar mecanicamente as cenouras com diâmetro acima e abaixo do permitido pela norma de classificação. O segundo sistema, utilizando um SVA, poderia realizar a classificação quanto à forma, realizando uma separação prévia das raízes quebradas e identificando o tamanho de cada raiz, para que o terceiro sistema, também um SVA, possa identificar os defeitos na superfície e efetuar a classificação final das raízes.

5.5 CONCLUSÕES

Este trabalho abordou o processo de construção e avaliação de um sistema de visão artificial utilizando câmeras line-scan para aquisição de imagens de raízes de cenoura para processamento em tempo real. Os testes realizados com a câmera resultaram na aquisição de uma imagem em 16 ms, indicando a possibilidade de adquirir 62 imagens por segundo utilizando apenas uma linha de alimentação de produtos, viabilizando assim o desenvolvimento de um sistema de classificação de produtos agrícolas utilizando câmeras line-scan.

Os métodos propostos para ajuste e calibração da câmera ofereceram resultados satisfatórios, obtendo-se imagens nítidas quando capturadas sem auxílio de espelhos.

O sistema de espelhos propostos para aquisição de todo o contorno das raízes apresentou problemas de distorção. Uma solução proposta seria a utilização de espelhos esféricos, acompanhando o contorno das raízes, devendo ser desenvolvido um algoritmo para reconstrução da imagem.

As imagens adquiridas apresentaram falta de alinhamento perpendicular ao CCD da câmera, provocando também distorções no espelho. Um sistema mecânico para alinhar a raiz no momento da queda poderia minimizar este problema.

5.6 REFERÊNCIAS BIBLIOGRAFICAS

BENNEDSEN, B. S.;PETERSON, D. L. TABB, A. **Identifying defects in images of rotating apples**. Computers and Electronics in Agriculture, v.48, n.2, p.92-102. 2005.

BLASCO, J.;ALEIXOS, N. MOLTÓ, E. **Computer vision detection of peel defects in citrus by means of a region oriented segmentation algorithm**. Journal of Food Engineering, v.81, n.3, p.535-543. 2007.

BROSNAN, T. SUN, D.-W. **Inspection and grading of agricultural and food products by computer vision systems--a review**. Computers and Electronics in Agriculture, v.36, n.2-3, p.193-213. 2002.

CEAGESP. Programa brasileiro para a melhoria dos padrões comerciais e embalagens de hortifrutigranjeiros: Classificação da cenoura: programa de adesão voluntária. CEAGESP: *Centro de qualidade em horticultura*, São Paulo, 2000.

CHAO, K.;YANG, C. C.;CHEN, Y. R.;KIM, M. S. CHAN, D. E. **Hyperspectral-Multispectral Line-Scan Imaging System for Automated Poultry Carcass Inspection Applications for Food Safety**. *Poult Sci*, v.86, n.11, November 1, 2007, p.2450-2460. 2007.

CHENG, Y T.; CHEN, Y.R.; LUO, Y. **NIR/MIR dual sensor machine vision system for online apple stem-end/calyx recognition**. *Transactions of the ASAE* 46, Issue 2, March 2003, pp. 551–558. 2003.

DALSA, PC-30 Piranha Color User's Manual. Disponível em em: http://www.dalsa.com/prot/mv/manuals/Piranha_Color_RoHS_User_Manual_03-032-10211-07.pdf . Acesso em: 05 de set. 2009.

DALSA, Application Notes- Line-scan Imaging Basics. Disponível em: http://www.dalsa.com/public/mv/appnotes/00541-00_03-32_L7inescan_Imaging_Basics.pdf. 2010. Acesso em: 05 de set. 2009.

EMBRAPA, Empresa Brasileira de Pesquisa Agropecuária. Disponível em: http://www.cnpq.embrapa.br/paginas/hortalicas_em_numeros/producao_hortalicas_2008. Acesso em: 04 de mar. 2010.

GAMBHIR, P. N., CHOI, Y.J.; McCARTHY, M. J. Development of rapid and non-invasive nuclear magnetic resonance method for identifying freeze damaged citrus fruits. *2004 IFT Annual Meeting*, Las Vegas, USA.

GHITA, O.;WHELAN, P. F.;CAREW, T. PADMAPRIYA, N. **Quality grading of painted slates using texture analysis**. *Computers in Industry*, v.56, n.8-9, p.802-815. 2005.

GUNASEKARAN, S. **Computer vision technology for food quality assurance**. *Trends in Food Science & Technology*, v.7, n.8, p.245-256. 1996.

IMA. PORTARIA Nº 488, DE 5 DE FEVEREIRO DE 2002. Estabelece padrões para cenoura destinada a certificação de origem e qualidade.

JAHNS, G.;MØLLER NIELSEN, H. PAUL, W. **Measuring image analysis attributes and modelling fuzzy consumer aspects for tomato quality grading**. *Computers and Electronics in Agriculture*, v.31, n.1, p.17-29. 2001.

KIM, M.;CHEN, Y.-R.;CHO, B.-K.;CHAO, K.;YANG, C.-C.;LEFCOURT, A. CHAN, D. **Hyperspectral reflectance and fluorescence line-scan imaging**

for online defect and fecal contamination inspection of apples. Sensing and Instrumentation for Food Quality and Safety, v.1, n.3, p.151-159. 2007.

KLINE, D. E.;SURAK, C. ARAMAN, P. A. **Automated hardwood lumber grading utilizing a multiple sensor machine vision technology.** Computers and Electronics in Agriculture, v.41, n.1-3, p.139-155. 2003.

KONDO, N.; AHMAD, U.;MONTA, M. MURASE, H. **Machine vision based quality evaluation of lyokan orange fruit using neural networks.** Computers and Electronics in Agriculture, v.29, n.1-2, p.135-147. 2000.

LANA, M.M.; SANTOS, F.F.;LUENGO, R.F.A.; MATOS, M.J.L.F.; TAVARES, S.A; MELO, M.F. **Hortaliças: como comprar, conservar e consumir cenoura.** Brasília: Embrapa Hortaliças , 1999 (Folder).

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

LOURO, Antônio H F ; MENDONÇA, Michelle M ; GONZAGA, A. Classificação de Tomates Utilizando Redes Neurais Artificiais. In: II Workshop de Visão Computacional - WVC'2006. **Anais...** Escola de Engenharia de São Carlos - São Carlos, v.1. p. 239-244. 2006.

PAULUS, I. SCHREVEENS, E. **Evaluating and Modelling the Size Classification of Apples.** Journal of Agricultural Engineering Research, v.74, n.4, p.411-419. 1999.

REESE, D.;LEFCOURT, A. M.;KIM, M. S. MARTIN LO, Y. **Using parabolic mirrors for complete imaging of apple surfaces.** Bioresource Technology, v.100, n.19, p.4499-4506. 2009.

SIMÕES, A. S.; COSTA, A. H. R. Classificação de laranjas baseada em padrões visuais. In: VI Simpósio Brasileiro de Automação Inteligente. Sociedade Brasileira de Automática - SBA. CDROM.14-17 Setembro 2003, p. 77-81.

UNAY, D. GOSSELIN, B. **Stem and calyx recognition on 'Jonagold' apples by pattern recognition.** Journal of Food Engineering, v.78, n.2, p.597-605. 2007.

VIEIRA, J.V.; PESSOA, H.B.S.V.; MAKISHIMA, N. Cultivo da cenoura (*Daucus carota L.*).Brasília: Embrapa Hortaliças, 1997. 19 p. (Instruções Técnicas, 13).

CAPÍTULO 6 – CONSIDERAÇÕES FINAIS

6.1 CONCLUSÕES

Para realizar a detecção de ombro verde/roxo, foram utilizados os descritores de cor do espaço RGB e um classificador estatístico. Como as imagens apresentaram sombras durante a aquisição, foram definidas cinco classes de diferentes regiões da imagem: fundo claro, fundo escuro, raiz sadia, ombro verde e ombro roxo.

O algoritmo proposto realizou a segmentação da imagem, e foram separadas as raízes que apresentaram uma incidência de ombro verde/roxo que comprometessem mais de 10% do comprimento da raiz. Foram utilizadas 60 imagens de raízes, sendo 20 de raízes sadias, 20 de raízes com incidência de ombro verde/roxo com atingindo menos de 10% do comprimento da raiz e 20 raízes com este defeito atingindo mais de 10% do comprimento da raiz. O algoritmo proposto atingiu 100% de exatidão na separação das raízes.

O algoritmo desenvolvido foi implementado utilizando a Linguagem C, associada com a biblioteca de software livre OpenCV. A utilização conjunta destes recursos permitiu um tempo de processamento de 0,023 s para uma imagem de 331x462 pixels, e de 0,094 segundos para imagens de 331x1061 pixels. Estes tempos são compatíveis para o desenvolvimento de sistemas de classificação em tempo real, permitindo no primeiro caso o processamento de até 100.0000 raízes por hora.

Para avaliação do formato das raízes de cenoura, foram avaliados 5 grupos de descritores para realizar a separação de raízes com formato aceitável das raízes tortas:

- Descritores topológicos, obtidos a partir de medidas geométricas das raízes;
- Descritores baseados nos momentos centrais, que são utilizados para medir a distribuição de massa de corpos rígidos

- Descritores baseados nos momentos invariantes, que são uma versão dos momentos centrais, porém invariantes à rotação do objeto;
- Descritores espectrais de Fourier aplicados ao gráfico obtido do contorno do objeto;
- Descritores espectrais de Wavelet aplicados ao gráfico obtido do contorno do objeto.

Os descritores espectrais e os descritores baseados nos momentos se mostraram insatisfatórios para realizar a classificação das raízes.

No caso dos descritores espectrais, o número e grau das reentrâncias das raízes variam a frequência do sinal obtido a partir do contorno. Como as imagens utilizadas não apresentaram reentrâncias significativas, o espectro de frequência do sinal de contorno não foi alterado significativamente, e conseqüentemente, os descritores espectrais não apresentaram diferenças entre as classes de cenouras deformadas (tortas) ou sem defeitos.

Apesar do número de trabalhos utilizando a teoria dos momentos para diferenciação de formas, a utilização destes descritores não apresentou resultado satisfatório. Neste trabalho, foram utilizados descritores baseados em momentos para diferenciar duas classes de formatos de cenoura, deformadas (tortas) ou sem deformação, enquanto a literatura tem apresentado a utilização de momentos para identificação do mesmo objeto em diferentes escalas e rotação, e em classificação de objetos de formatos semelhantes. No caso de raízes de cenouras, as raízes apresentam diferentes deformações, com diferentes formatos, gerando assim problemas na classificação.

Os descritores topológicos apresentaram melhores resultados na separação das raízes tortas, apresentando uma exatidão global de 93,3% 3 um coeficiente kappa de 86,1%, sendo indicados para implementação de um sistema automático de separação das raízes quanto ao formato.

Outro defeito considerado grave para a rejeição das raízes de cenoura são as rachaduras. Para avaliar este defeito, foram utilizados duas abordagens:

- Estatística, utilizando 4 descritores de textura de Halarick;
- Espectral, utilizando os descritores de energia obtidos de imagens sub-amostradas pela aplicação da transformada de Wavelet.

Os dois grupos de descritores foram aplicados a classificadores utilizando redes neurais artificiais. Porém, como a rachadura é um defeito que apresenta pouca variância quando analisada pixel a pixel ou em pequenas vizinhanças, foram utilizados recortes da cenoura, que foram classificados contendo ou não rachaduras. Para evitar falsos positivos, foram consideradas como raízes defeituosas aquelas que apresentaram 3 ou mais recortes contíguos foram classificados como apresentado rachaduras.

Utilizando esta metodologia, os classificadores utilizando a abordagem estatística apresentou uma exatidão global de 94,37% e utilizando a abordagem espectral, uma exatidão global de 95 %, indicando que os dois modelos podem ser utilizados.

Foi ainda avaliada a utilização de uma câmera line-scan para realizar a captura de imagens com elevadas taxas de aquisição e transferência de dados para um sistema implementado em plataforma IBM-PC, implementado em linguagem C. Foi desenvolvida uma metodologia para o ajuste de foco e realizada a calibração da câmera para adquirir imagens de raízes de cenoura em movimento, no caso em queda livre, utilizando espelhos.

Os resultados qualitativos do ajuste de foco e calibração foram satisfatórios, mas a aquisição de imagens utilizando espelhos apresentou problemas devido ao diâmetro circular apresentado pelas raízes. Para contornar este problema, trabalhos futuros poderão ser desenvolvidos utilizando espelhos esféricos.

A aquisição de imagens utilizando um sistema de queda livre também apresentou problemas, pois durante a queda as raízes apresentaram movimento de rotação, que foi capturado pela câmera, distorcendo a imagem.

A utilização de um sistema de esteiras que impulsionasse a raiz a uma velocidade maior do que a queda livre poderia minimizar este problema.

6.2 SUGESTÕES PARA TRABALHOS FUTUROS

A utilização da linguagem C associada a biblioteca OpenCV mostrou resultados satisfatórios quanto à velocidade de processamento e à variedade de recursos disponíveis na biblioteca, sendo indicada para desenvolvimento de trabalhos futuros em aplicações de classificação de diversos produtos hortigranjeiros em tempo real.

Neste trabalho foram detectados defeitos de rachaduras, incidência de ombro verde e quanto à deformação de raízes (tortas ou sem deformação). Para realizar a classificação de acordo com a regulamentação proposta pelo CEAGESP, devem ser ainda desenvolvidos algoritmos para detecção de alguns defeitos mais específicos, como raízes quebradas, murchas e apresentando radículas, pragas ou doenças.

No desenvolvimento do trabalho ocorreram problemas na aquisição da imagem utilizando a câmera line-scan devido à falta de um mecanismo adequado para transporte das raízes quando estas passam pela câmera e pela utilização de espelhos planos. Uma sugestão para trabalhos futuros seria o desenvolvimento de um sistema que possa primeiro identificar problemas no formato, que pode utilizar a imagem 2D da raiz, e depois um novo estágio que , utilizando um mecanismo de transporte adequado, possa rotacionar a raiz para que esta seja imageada pela câmera, ou ainda um sistema adequado de espelhos esféricos que permitam uma melhor aquisição do contorno da imagem.