



XI Encontro de Modelagem Computacional

17 a 19 de novembro de 2008

Organização



Organizadores

José Adilson de Castro
Alexandre S. Francisco
Francisco D. Moura Neto

Realização

Escola de Engenharia
Industrial Metalúrgica de
Volta Redonda/UFF

Apoio

CNPq
PUVR

Editora



ISBN 978-85-228-0487-0

DESENVOLVIMENTO DE UM MODELO DE VISÃO COMPUTACIONAL PARA INFERÊNCIA DA QUALIDADE DE FRUTAS

Érika Sayuri Tezuka – erika_tezuka@dc.ufscar.br

Universidade Federal de São Carlos, Departamento de Computação,
São Carlos, Sp, Brasil

Paulo Sérgio de Paula Herrmann Júnior – herrmann@cnpdia.embrapa.br

Embrapa Instrumentação Agropecuária
São Carlos, SP, Brasil

Paulo E. Cruvinel – cruvinel@cnpdia.embrapa.br

Embrapa Instrumentação Agropecuária
São Carlos, SP, Brasil

***Resumo.** Este trabalho apresenta um modelo computacional para a classificação de frutas através da análise de imagens adquiridas por câmera fotográfica. O sistema em desenvolvimento utiliza técnicas de processamento de imagens: filtragem, processamento de cor, processamento de área, processamento de textura e classificação que integram o modelo de decisão que se baseia em indicadores de interesse para especificação da qualidade dos produtos analisados.*

***Palavras chaves:** modelo computacional, processamento de imagens, indicadores de qualidade, modelo de decisão.*

1. INTRODUÇÃO

O Brasil é o 3º produtor mundial de frutas e exportou 920 mil toneladas em 2007 aproximadamente 36% a mais que em 2006 obtendo um rendimento de 644 milhões de dólares. O grande potencial produtivo do país, favorecido pela diversidade climática, possibilita a produção de vários tipos de frutas. Em um setor tão importante economicamente, o estabelecimento de normas de certificação, é fundamental para a comercialização de frutas in natura, pois muitas são destinadas ao mercado externo são submetidas aos padrões de qualidade estabelecidos por organismos internacionais (Dornfeld *et al.*, 2005). Vários atributos das matérias-primas são adotados para critério de classificação, como: tamanho, cor, maturação, ausência de manchas ou outros defeitos causados por fungos e insetos, simetria, textura, sabor e odor. Esses atributos são relevantes para a seleção e classificação das frutas que geralmente é realizada de maneira manual (Simões & Costa, 2003). A automação deste processo baseada em imagens digitais apresenta algumas dificuldades como: a) não há uma descrição formal dos padrões das frutas; b) não há ferramentas computacionais e modelos

consolidados para a classificação de frutas; c) dependência das condições de iluminação do ambiente.

O controle de qualidade em frutas requer métodos seguros, capazes de avaliar com precisão razoável e possivelmente de um modo não-destrutivo as suas características físicas. O julgamento obtido dessa comparação é que permite fazer o enquadramento do produto em grupo, classe e tipo, tornando possível uma interpretação única.

Alguns trabalhos têm sido propostos utilizando técnicas de processamento de imagens digitais para classificação de laranjas baseada em padrões visuais (Simões & Costa, 2003), identificação do estágio de maturação de bananas (*Musa Sapientum*) baseado na cor (Mendoza e Aguilera, 2004), medida de área e volume (XU *et al.*, 2006), determinação do volume do kiwi (*Actinidia Chinensis*) (Rashidi, 2007), entre outros.

O presente trabalho apresenta um modelo computacional para classificação de frutas com base na análise de textura abordando o modelo estatístico, cor baseado no modelo HSI e cálculo da área da superfície.

2. INDICADORES DE QUALIDADE

O parâmetro qualidade para classificação de frutas neste trabalho seguiu três aspectos distintos: textura, cor e área da superfície.

2.1 Textura

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

As três principais abordagens usadas no processamento de imagens para descrever a textura de uma região são: Estrutural, Estatística e Espectral (Jain, 1989).

As imagens das frutas podem ser caracterizadas pela suavidade ou pela rugosidade. De um ponto de vista matemático, para caracterizar a textura das imagens, é descrito por alguns autores como um atributo que representa o arranjo de espaço dos níveis de cinza dos pixels em uma região da imagem (Haralick, 1973; Pratt, 1991; Ribeiro Jr., 1995; Tuceryan & Jain, 1998; Stein, 2005; De-Hui *et al.*, 2006; Nunes e Conci, 2007).

A matriz de co-ocorrência é um método freqüentemente citado para análise de textura estatística e é baseado na extração de várias características texturais de uma matriz de co-ocorrência nivelada em cinza (GLCM), definido por um deslocamento δ e uma direção θ . Uma vez que o GLCM é definido, vários descritores texturais podem ser avaliados (Billy *et al.*, 2006). São considerados os mais usados: a entropia, a energia, o contraste, homogeneidade e correlação.

2.2 Cor

O processo de seleção de frutas consiste normalmente na inspeção humana considerando características como cor e tamanho (Gonzalez e Woods, 1992). Um sistema automático para tal finalidade deve ser capaz de identificar os parâmetros de forma adequada. A caracterização da luz é essencial para ciência das cores.

O HSI é de grande interesse, uma vez que permite separar as componentes de matriz, saturação e intensidade da informação de cor em uma imagem. Sua utilização é mais intensa

em um sistema de visão artificial, pois suas características tornam-se uma ferramenta ideal para o desenvolvimento de algoritmos de processamento de imagens fortemente baseados no modelo de percepção de cor pelo ser humano (Gonzalez e Woods, 1992). Como por exemplos: projeto de sistemas de imageamento para determinação automática do amadurecimento de frutas e vegetais ou sistemas para correspondência de amostras de cores, ou para inspeção de qualidade de produtos coloridos.

2.3 Área da Superfície

A medida da área da superfície fornece importantes informações para agricultura e aplicações de processamento de alimentos. O tamanho da fruta é importante para comercialização, pois os consumidores preferem frutas com peso e formato uniforme. O método para frutas com formato irregular possibilita a estimação da área da superfície de frutas de qualquer formato devido ao modelo matemático utilizado. A imagem da fruta é cortada em N fatias, cada uma com ângulo $\Delta\theta$. Em seguida calcula-se o perímetro de cada fatia e a soma desses perímetros corresponde à área da superfície do objeto.

3. TÉCNICAS DE CLASSIFICAÇÃO

A maior tarefa após a extração de características de uma imagem é classificar o objeto extraído em alguma categoria (Jain, 1989). A classificação de imagens e extração de características tem objetivos muito próximos.

As técnicas de classificação supervisionadas baseiam-se na disponibilidade de uma amostra representativa de cada classe identificada. Estas amostras são informações a respeito do comportamento médio das classes e podem ser denominadas como "pixels de treinamento" do sistema.

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

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

4. METODOLOGIA

Dentro do contexto agrícola, a Embrapa Instrumentação Agropecuária vem desenvolvendo métodos para inferência da qualidade de frutas. O modelo desenvolvido é composto pelas seguintes etapas:

Aquisição da Imagem: Para a aquisição das imagens de frutas a ser utilizado será uma câmera fotográfica e ambiente de iluminação controlado.

Pré-Processamento: Em processamento de imagens a filtragem tem o papel de eliminar ou atenuar ruídos, melhorar o contraste, suavizar ou realçar a imagem a ser analisada.

Processamento de Cor: Através da análise visual da cor serão identificados os estágios de maturação da fruta, assim como injúrias. Será utilizado o modelo HSI para as análises e estruturação do método.

Processamento de Área: O tamanho de frutas é muito importante para a comercialização. Por esta razão um modelo matemático será utilizado para estimar a área da superfície das frutas, formado pelas medidas referenciadas nas imagens a serem analisadas.

Processamento de Textura: Textura é uma propriedade importante na percepção de regiões e superfícies, contendo informações sobre a distribuição espacial das variações de tonalidade locais em valores de pixels que se repetem de maneira regular ou aleatória ao longo do objeto ou imagem. Serão utilizadas as abordagens estatísticas.

Organização da Informação: Após a fase de processamento da imagem de frutas, um modelo de decisão será utilizado para organizar as informações obtidas sobre os atributos de inferência para qualidade de frutas. Tomando por base árvores de decisão, as quais representam um meio eficiente de construir classificadores que predizem classes baseadas nos valores de atributos de um conjunto de dados de imagens digitais.

Emissão do Relatório de Análise: Dados relevantes ao estudo da qualidade de frutas serão registrados em um relatório para evidenciar e facilitar a ação de usuários.

O diagrama de bloco da Figura 1 ilustra o modelo desenvolvido.

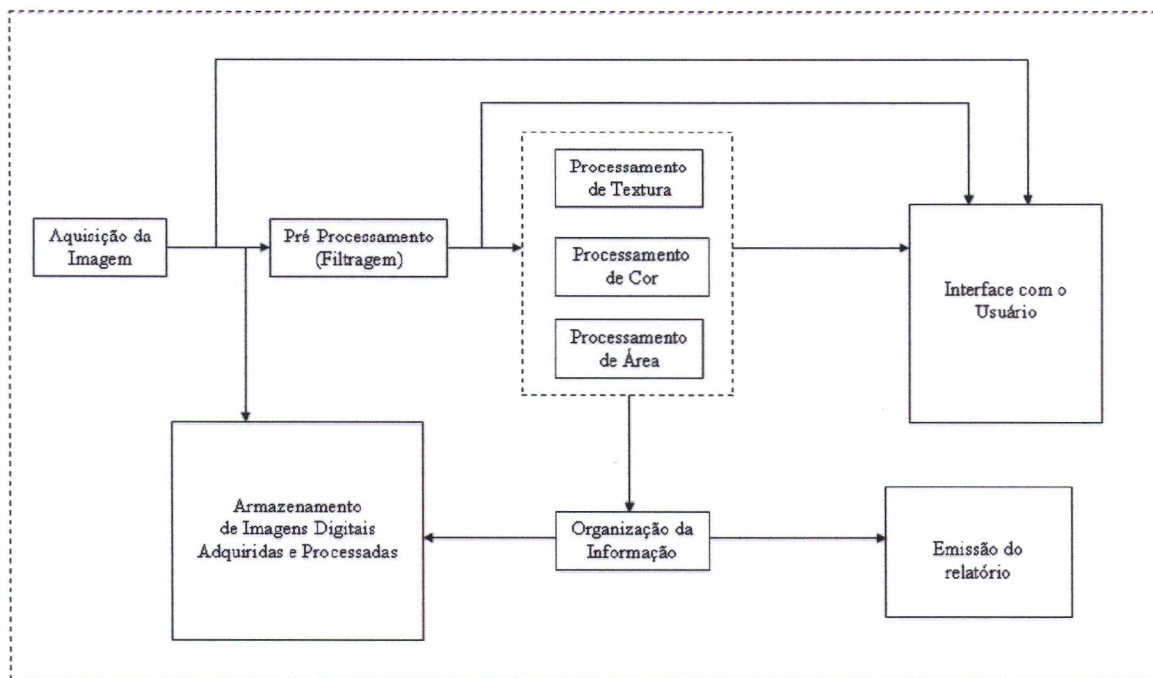


Figura 1- Diagrama em bloco do modelo de visão computacional para inferência da qualidade de frutas.

A figura 2 abaixo apresenta o pseudocódigo geral do modelo computacional para classificação de frutas.

```

variáveis
    ng: inteiro {Número de níveis de cinza da imagem}
fim-variáveis
Begin
    variáveis
        tamMasc: inteiro
        mc[ng][ng]: inteiro
        deslocamento, ângulo, N: inteiro
        perímetro, área, raio1, raio2, ang, vetorText[0]: real
    
```

```

fim-variáveis
{Aquisição da imagem}
Begin
  ler(imagem)
end;
{Pré-Processamento da imagem}
Begin
  {Equalização}
  Begin
    equalizaHistograma(imagem)
  end;
  {Filtragem}
  Begin
    leia(tamMasc)
    {Passa-baixa}
    filtroMediana(imagem,tamMasc)
    {Detecção de Bordas}
    filtroSobel(imagem,tamMasc)
  end;
end;
{Bloco de Análise de Textura}
Begin
  {Análise de Textura}
  Begin
    mc <- matrizCoOcorrencia(imagem,deslocamento,ângulo)
    vetorText[0] = homogeneidade(mc)
  end;
end;
{Bloco de Processamento de Cor}
Begin
  ConversaoRGBparaHSI
end;
{Bloco de Processamento da área}
Begin
  perímetro(raio1,raio2,ang,N)
  área(raio1,raio2,ang,N)
end;
{Bloco da Classificação}
Begin
  supervisionada
end;
Begin
  Relatório
end;
end.

```

Figura 2 – Pseudocódigo geral do modelo computacional.

O modelo inicia com a aquisição e leitura da imagem de uma fruta. Esta passa por uma etapa de pré-processamento para eliminação de ruídos e melhoria do contraste. Para isso é utilizado o filtro da mediana que consiste em ordenar os pixels de uma janela ao redor da amostra alvo. Nesta técnica, o nível de cinza de cada pixel é substituído pelo valor mediano de níveis de cinza na vizinhança daquele pixel. O valor mediano m de um conjunto de valores é tal que metade dos valores no conjunto é menor ou igual a m e a outra metade é constituída de valores maiores que m . O primeiro passo na implementação desse filtro é ordenar os valores da vizinhança que pode ser 3x3, 5x5, 7x7 ou maiores de acordo com a necessidade.

O contraste é uma medida qualitativa e que está relacionada com a distribuição dos tons de cinza em uma imagem. Equalizar o histograma significa obter a máxima variância do histograma de uma imagem, obtendo assim uma imagem com o melhor contraste. Para realização da equalização de uma imagem colorida é necessário separar as várias componentes RGB, equalizá-las e juntar as várias componentes para obter a imagem. A equalização pode ser obtida através da aplicação da fórmula:

$$s_k = T(r_k) = \sum_{j=0}^k \frac{n_j}{n} = \sum_{j=0}^k p_r(r_j) \quad (1)$$

A Eq.1 é uma função de distribuição acumulada utilizada para equalizar um histograma. O r_k é normalizado entre 0 e 1 com $k=0,1,\dots, L-1$ e L é o número de níveis de cada componente da imagem digitalizada. O n é o número total de pixels na imagem e n_j o número de pixels cujo nível de componente corresponde a j , a divisão de um pelo outro nos dá a probabilidade do j -ésimo nível de cinza [$p_r(r_j)$].

O primeiro passo na análise de imagens é a segmentação que consiste em usar o computador para definir na imagem, recortes automáticos ao redor de objetos de interesse. Algoritmos de segmentação permitem achar diferenças entre dois ou mais objetos, e distinguir as partículas umas das outras e do fundo. A detecção de bordas é a abordagem mais comum para a detecção de descontinuidades. Podemos definir uma borda como sendo o limite entre duas regiões com propriedades relativamente distintas de nível de cinza. A idéia por trás deste método é a computação de um operador local. Visto que, em imagens digitais, as bordas são, geralmente, levemente borradas, podemos aplicar a primeira derivada no perfil de níveis de cinza. Esta derivada será nula nas áreas de nível de cinza constantes, positiva na primeira borda e negativa na segunda. O operador local usado é conhecido como operador de gradiente, que é dado por um vetor que contém as derivadas parciais de X e Y (vertical e horizontal). O vetor gradiente aponta na direção de mudança mais rápida da função na posição (x,y) . A idéia é criar outra imagem aplicando um operador conhecido como operador de Sobel, que possuem a vantagem de oferecer ao mesmo tempo os efeitos de diferenciação e de suavização. Uma vez que a derivação aumenta o ruído, a suavização é desejável. Para implementar o operador de Sobel, pega-se um pixel da imagem original e é analisada os vizinhos em todas as direções, obtendo suas intensidades.

$$\begin{bmatrix} z1 & z2 & z3 \\ z4 & z5 & z6 \\ z7 & z8 & z9 \end{bmatrix}$$

As derivadas parciais utilizando Sobel ficam assim:

$$\left. \begin{aligned} G_x &= (z7 + 2z8 + z9) - (z1 + 2 * z2 + z3) \\ G_y &= (z3 + 2z6 + z9) - (z1 + 2 * z4 + z7) \\ \text{GradF}(z5) &= \text{abs}(G_x) + \text{abs}(G_y) \end{aligned} \right\} \quad (2)$$

Calcula-se então o gradiente para $z5$, para a obtenção do próximo valor desloca-se toda a máscara.

A análise de imagens é uma das principais tarefas envolvidas em um sistema de classificação, sendo a textura a característica mais importante. O processamento é feito a partir da matriz de co-ocorrência da imagem, na qual os índices das linhas e colunas representam os diferentes valores de níveis de cinza.

O método consiste em avaliar um conjunto de matrizes de co-ocorrência para se caracterizar a textura à qual elas se referem, utilizando-se um ou mais descritores. Para cada imagem é gerada uma matriz de co-ocorrência na direção θ (0° , 45° , 90° e 135°) e distância δ (igual a 1). O descritor adotado para este modelo foi a homogeneidade, dada pela seguinte equação:

$$\text{homogeneidade} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1+(i-j)^2} P_{\delta\theta}(i,j) \quad (3)$$

O N_g é o número de níveis de cinza da imagem. A entrada $P(i, j)$ desta matriz é o número de ocorrências de um par de níveis cinza, i e j , para o deslocamento especificado.

O modelo HSI é bastante usado para o estudo de cores em processamento de imagens. A matiz (hue) é o atributo associado com o comprimento de onda dominante, representando a cor dominante percebida pelo observador, a saturação (saturation) está relacionada com a pureza, isto é, o quanto a cor é diluída pela luz branca. A intensidade determina a intensidade de luz que uma superfície tem a capacidade de refletir ou uma fonte luminosa de emitir.

Neste modelo as componentes são definidas em um triângulo de cor. A componente H de do ponto de cor P é o ângulo do vetor com relação ao eixo vermelho. Assim, se este ângulo é nulo, tem-se vermelho, se for 60° tem-se amarelo. A componente S é proporcional à distância de P ao centro do triângulo. Quanto mais distante do centro, mais saturada é a cor. A componente I é medida por uma linha passando perpendicularmente pelo centro do triângulo.

Para o processamento da área da superfície é feito uma reconstrução 3D do objeto obtendo assim os dados necessários para o cálculo da área. Primeiramente é calculado o perímetro do objeto através da seguinte equação:

$$P(z) = \sum_{i=1}^N \left(r_i^2 + r_{(i+1) \bmod N}^2 - 2r_i + r_{(i+1) \bmod N} \cos \Delta\theta \right)^{1/2} \quad (4)$$

A imagem da fruta é dividida em N fatias com um intervalo angular $\Delta\theta$ e raios r_i e $r_{(i+1)}$ dados em cm. Depois de calculado o perímetro de cada fatia pode-se obter a área da superfície com a equação:

$$S = \int_a^b P(z) dz = \sum \left[\sum_{i=1}^N \left(r_i^2 + r_{(i+1) \bmod N}^2 - 2r_i + r_{(i+1) \bmod N} \cos \Delta\theta \right)^{1/2} \right] \quad (5)$$

A área superfície é obtida através da soma dos perímetros das fatias e o resultado é dado em cm^2 .

A classificação de imagens digitais associa a cada pixel da imagem um rótulo ou um tema de interesse. Para a classificação supervisionada é abordado o algoritmo de máxima verossimilhança Gaussiana. Utiliza-se a média e a covariância das amostras de treinamento, para um cálculo estatístico da probabilidade de um pixel pertencer à outra classe utiliza-se funções de densidade de probabilidade.

5. RESULTADOS

Para avaliação da abordagem do modelo em desenvolvimento foram analisadas bananas (*Musa Sapientum*) que sofreram injúrias devido ao processo de armazenamento. A figura 3 apresenta a imagem original da fruta, a figura 4 ilustra o histograma em RGB da imagem original e a figura 5 mostra o resultado da operação de segmentação com base em limiarização RGB, cujos valores de referência foram tomados como $R=114$, $G= 78$ e $B= 67$, com tolerância de 45.




Figura 3 – Imagem original da banana.




Figura 4 – Histograma da Imagem Original.



Figura 5 – Resultado da operação de segmentação com base em limiarização RGB, cujos valores de referência foram tomados como $R=114$, $G= 78$ e $B= 67$, com tolerância de 45.

O modelo apresentado neste trabalho analisa a textura para identificar as propriedades físicas da superfície do produto, a cor para a identificação de injúrias e estágio de maturação, com a informação da área da superfície poder identificar a fruta em questão e dessa forma espera-se aprimorar o método de classificação.

6. CONCLUSÕES

O modelo computacional em estudo viabilizou a estruturação de um método que encontra aplicação na identificação de estruturas de manchas marrons ou injúrias em bananas e seu estado de amadurecimento. Considerando que a classificação de pixel é uma tarefa que requer especialidade até mesmo para os seres humanos o modelo desenvolvido apresenta potencialidade para que se classifiquem frutas de forma adequada com precisão, o que é de interesse para o correto atendimento a consumidores.

REFERÊNCIAS

- BILLY L.; ARVISENET G.; POINOT P.; CHEVALLIER S.; ROYER G.; VIGNEAU E.; PROST C., Image Texture Analysis of Apples Broken down in a Mastication Simulator Prototype, 13th World Congress of Food Science & Technology, pp. 775-782, 2006.
- DE-HUI, K.; BAO-CAO Y.; YAN L.; YUN-HUI S., A rapid Texture Synthesis Algorithm Based on Clustering Preprocessing, IJCSNS – International Journal of Computer Science and Network Security, vol. 6, n. 6, 2006
- DORNFELD, C. H.; ALMEIDA, B. V. G.; MANCO, R. J., Analysis of the Quality and Valorization of Integrated Apples Production: An Study in the Wholesale Market of São Paulo – Brazil, V International PENSA Conference, pp.1-10, 2005.
- GONZALEZ, C. R.; WOODS E. R., Processamento de Imagens Digital, Edgard Blücher Ltda., 1992.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I., Textural Features for Image Classification, IEEE Transactions on Systems, Man and Cybernetics, vol. 3, n.6, pp. 610-621, 1973.
- JAIN, K. A., Fundamentals of Digital Image Processing, Prentice-Hall International Editions, 1989.
- MENDOZA F.; AGUILERA, J. M., Application of Image Analysis for Classification of Ripening Bananas. Journal of Food Science, vol. 69, n.9, pp. E471-E477, 2004.
- NUNES, E. O.; CONCI A., Segmentação por textura e localização do contorno de regiões em imagens multibandas. IEEE, vol.5, n.3, pp. 185-192, 2007.
- PRATT, W. K., Digital Image Processing, John Wiley & Sons, Inc., 1994
- RASHIDI M., Determination of kiwifruit volume using image processing. Journal of Agricultural and Biological Science, vol. 2, n.6, 2007.
- RIBEIRO Jr. E., Análise de Atributos Visuais em Imagens Texturais utilizando Técnicas Espectrais, Dissertação de Mestrado, Universidade Federal de São Carlos, 1995.
- SCHOWENGERDT, R. A., Models and methods for image processing. 2. ed., 1997.
- SIMÕES, S.A.; COSTA, R. H. A., Classificação de Laranjas Baseadas em padrões Visuais, Laboratório de Técnicas Inteligentes, In: Simpósio Brasileiro de Automação Inteligente, pp. 77-81, 2003.
- STEIN T., Avaliação de Descritores de Textura para Segmentação de Imagens, Dissertação de Mestrado, Universidade Federal do Paraná, 2005.

TUCERYAN M.; JAIN A.K., Texture Analysis. In: The Handbook of Pattern Recognition and Computer Vision (2nd Edition), Eds. Chen C.H., Pau L F., Wang P S.P., World Scientific Publishing Co., 207-248, 1998

XU X.; EIFERT J.; ZHAN P., Area and volume measurements of objects with irregular shapes using multiple silhouettes. Optical Engineering, vol. 45 (2), 2006.

DEVELOPMENT OF A COMPUTATIONAL MODEL FRUIT QUALITY INFERENCE

***Abstract.** This paper presents a model computational filter based on image for classification of fruit for the analysis of images acquired by camera. The model developed uses techniques of image processing: filtering, color processing, area processing, texture processing and classification incorporating the type of decision based on indicators of interest for specifying of computational products quality model.*

***Keywords:** computational model, image processing, quality indicator, type of decision*