



SBI Agro
2009

7º Congresso Brasileiro de Agroinformática
Agroinformática e a sustentabilidade do agronegócio e dos recursos naturais



21 a 25 de setembro de 2009
Universidade Federal de Viçosa • Viçosa/MG



IDENTIFICAÇÃO DE DEFEITOS EM BANANAS ATRAVÉS DO MAPEAMENTO DE ÁREAS DE RISCO UTILIZANDO ANÁLISE DE TEXTURA E VISÃO COMPUTACIONAL

ÉRIKA SAYURI TEZUKA¹
PAULO ESTEVÃO CRUVINEL²

RESUMO: A banana é o fruto da bananeira, uma planta herbácea vivaz acaule da família *Musaceae* (gênero *Musa*). As bananas constituem o quarto produto alimentar mais produzido no mundo, a seguir ao arroz, trigo e milho. São originárias do sudeste da Ásia, sendo atualmente cultivadas em praticamente todas as regiões tropicais do planeta, principalmente no Brasil. Este trabalho apresenta um modelo computacional para classificação de bananas através da análise de imagens adquiridas por câmera fotográfica digital. O modelo desenvolvido utiliza técnicas de processamento de imagens, como limiarização, crescimento de regiões e análise de textura que integram o modelo de decisão o qual identifica as áreas de risco devido a injurias sofridas na pós-colheita.

PALAVRAS CHAVES: Visão computacional, Análise de textura, Modelo de decisão, Pós colheita.

INJURY IDENTIFICATION OF BANANAS BASED ON TEXTURAL ANALYSIS AND COMPUTER VISION

ABSTRACT: Banana is the common name for a type of fruit and also the herbaceous plants of the genus *Musa* which produce this commonly eaten fruit. They are native to the tropical region of Southeast Asia. Today, they are cultivated throughout the tropical countries, even in Brazil, and are of the family *Musaceae*. This paper presents an image processing model for bananas injury identification and classification. The model is based on threshold, region growing, and texture analysis and allows support for decision making in post-harvesting processes.

KEYWORDS: Computer vision, Texture analysis, Decision model, Post-harvesting.

1. INTRODUÇÃO

A fruticultura é uma das atividades agrícolas que mais cresce no Brasil, o qual é o terceiro produtor mundial (EMBRAPA, 2008). Em um setor tão importante economicamente, o estabelecimento de normas de certificação, torna-se fundamental para a comercialização de frutas in natura, pois muitas frutas destinadas ao mercado externo são submetidas aos padrões de qualidade estabelecidos por organismos internacionais (DORNFELD et al., 2005). A fruticultura é considerada uma das atividades mais dinâmicas da economia brasileira, apresentando uma evolução contínua. Atende o mercado interno e vem ganhando espaço no mercado internacional (IBRAF, 2008).

¹Formação (mestranda em Ciência da Computação), Instituição (UFSCar – Universidade Federal de São Carlos), Email: erika_tezuka@dc.ufscar.br

²Formação (Doutor em Automoção), Instituição (Embrapa Instrumentação Agropecuária), Email: cruvinel@cnpdia.embrapa.br

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

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 presente trabalho apresenta um modelo computacional para identificação de defeitos em banana através do mapeamento das áreas de risco utilizando limiarização, crescimento de regiões e textura.

2. OBJETIVO

Este trabalho tem por objetivo o desenvolvimento de um método para auxílio ao tomador de decisão em processos de pós-colheita de bananas (*Musa cavendishii*). Injúrias em bananas prejudicam o produtor que deve eliminar os produtos com defeitos graves antes do seu embalamento, de forma a manter e agregar valor ao produto.

3. MATERIAIS E MÉTODOS

Neste trabalho foram analisadas imagens de cachos de bananas (*Musa cavendishii*) que apresentam injúrias de pós-colheita. Os métodos utilizados para a identificação dessas injúrias foram limiarização, crescimento de regiões e análise de textura.

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

Uma imagem limiarizada $g(x, y)$ é definida como na equação a seguir:

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

Onde $f(x, y)$ corresponde ao nível de cinza do *pixel* e L é um valor de tom de cinza predefinido denominado limiar.

O crescimento de regiões é um procedimento que agrupa *pixels* ou sub-regiões em regiões maiores. A mais simples dessas abordagens é a agregação de *pixels*, que começa com um conjunto de pontos "semente" e, a partir deles, cresce as regiões anexando a cada ponto semente aqueles *pixels* que possuam propriedades similares (PRATT, 1991).

Em muitos algoritmos de visão de máquina e processamento de imagens, são feitas suposições simplificadas sobre a uniformidade de intensidades nas regiões da imagem. Uma textura se caracteriza pela repetição de um modelo sobre uma região, sendo este modelo repetido em sua forma exata ou com pequenas variações (HARALICK, 1973).

Neste trabalho foi utilizada a abordagem estatística que usa as matrizes de co-ocorrência que formam a base para elaboração de diversas medidas estatísticas conhecidas como descritores de Haralick.

O método está baseado na extração de várias características texturais de uma matriz de co-ocorrência nivelada em cinza (GLCM) de tamanho $N_g \times N_g$ (N_g é o número de níveis de cinzas) definido para um deslocamento de uma distância δ junto com uma determinada direção θ . O descritor textural considerado foi o contraste que é definido na equação 2.

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

Sonka e colaboradores (SONKA et al., 1998) descrevem o algoritmo de agrupamento de primitivas como: regiões formadas a partir de primitivas de baixo nível podem ser consideradas como primitivas de nível mais alto e o processo de agrupamento pode ser repetido para estas novas primitivas.

O método para mapeamento das áreas de risco com a análise de textura foi desenvolvido baseado no algoritmo de agrupamento de primitivas apresentando as regiões de interesse baseado no valor de textura de cada região conforme mostra a Figura 1.

Algoritmo: Algoritmo para obtenção do mapa das áreas de risco	
1.	Obtenção do mapa de textura: <ol style="list-style-type: none"> a. Fazer um janelamento na imagem original; b. Calcular o valor de textura de cada janela; c. Normalizar os valores de textura; d. Redistribuir os valores normalizados na paleta de cinza (0-255) para a visualização do mapa; e. Conectar as classes iguais ou dentro de um limite;
2.	Encontrar na imagem original apenas as regiões de interesse.
3.	Calcular o mapa de textura da banana. <ol style="list-style-type: none"> a. Unir o mapa de textura e a imagem das regiões; b. Calcular para cada região o valor médio;

Figura 1 – Algoritmo para obtenção do mapa das áreas de risco.

4. RESULTADOS

Para avaliação da abordagem do modelo em desenvolvimento foram analisadas bananas (*Musa cavendishii*) que sofreram injúrias devido ao processo de armazenamento. As Figuras 2 e 3 ilustram a imagem original, segmentação com base em limiarização RGB, o mapa de textura, as regiões de interesse com o mapa de textura e o mapa de risco com o valor médio de cada região, respectivamente.

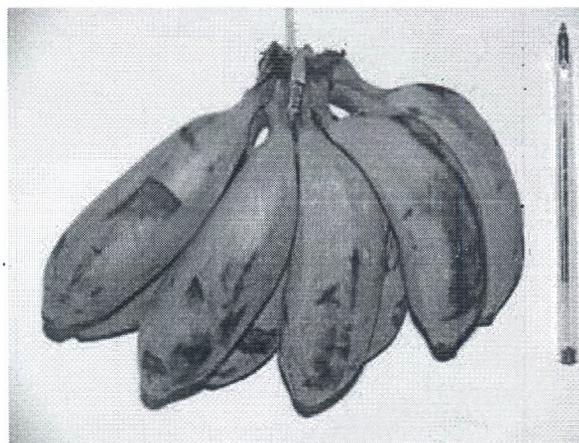


Figura 2 – Imagem original apresentando cacho com bananas que apresentam injúrias de pós-colheita.

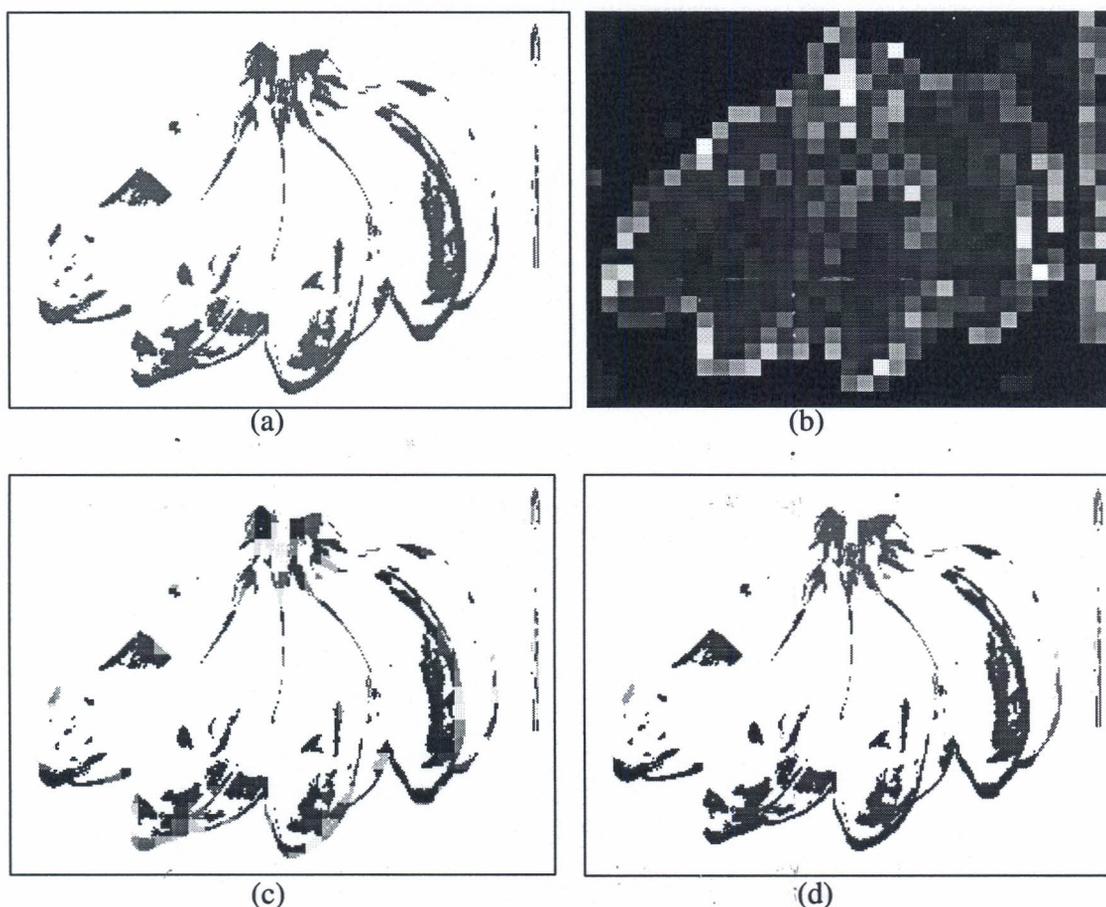


Figura 3 – (a) Resultado da operação de segmentação com base em limiarização RGB, cujos valores de referência foram tomados como R= 114, G=102 e B=93, com tolerância de 50, (b) Mapa de textura obtida a partir da imagem original em tons de cinza, (c) Regiões de interesse com o mapa de textura e (d) Mapa de risco com o valor médio de cada região.

O modelo apresentado neste trabalho utiliza a textura para identificar as propriedades físicas da superfície do produto fornecendo um mapa das áreas de risco.

5. CONCLUSÕES

O modelo viabilizou a estruturação de um método que encontra aplicação na identificação de estruturas de manchas marrons ou injúrias em bananas através do mapa das áreas de risco. Levando em consideração que a classificação de *pixel* é uma tarefa complicada até mesmo para os seres humanos o modelo desenvolvido apresenta potencialidade para que se classifiquem as áreas defeituosas de forma adequada e com precisão.

6. REFERÊNCIAS BIBLIOGRÁFICAS

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

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

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

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

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

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

SONKA, M.; HLAVAC, V.; BOYLE, R. **Image processing: Analysis and Machine Vision**. 2 nd ed. Victoria: Thomson, 1998.