

Foto: Valentim Monzane



Método Laboratorial para Inferência da Qualidade de Bananas (Amadurecimento e Injúrias) com Visão Computacional

Paulo E. Cruvinel¹
Paulo Sérgio de Paula Herrmann Júnior²
Valdique Martins Medina³

Neste comunicado técnico é apresentado um método para diagnóstico precoce da formação de manchas marrons em bananas em cachos ou individualmente, bem como de coloração da casca como indicativo da maturação dos frutos. Fundamentado em técnicas do processamento digital de imagens supervisionado, o diagnóstico precoce com base no uso de visão computacional apresenta confiabilidade e menor tempo de análise quando comparado ao uso direto de visão humana no processo de decisão. A banana é considerada a quarta cultura agrícola mais importante do planeta, depois do arroz, do trigo e do milho. É uma das mais antigas frutas consumidas pelo homem. Também, é a mais popular de todas, presente na dieta alimentar dos povos do mundo inteiro.

A banana é, hoje, cultivada na maioria dos países tropicais e subtropicais (estima-se que em mais de 120). Devido ao conteúdo de vitaminas e sais minerais (TWFORD, 1967; GOMES, 1988), ao seu valor energético e custo relativamente baixo, a banana é parte integrante da alimentação de populações de baixa renda das zonas produtoras. É, também, cultura importante para fixação da mão-de-obra rural.

Segundo o IBRAF (2007) os principais países produtores são, respectivamente, Índia (20%), Brasil (10%), Equador (8%), China (7%) e Filipinas (6%), que respondem, juntos, por 51% do total produzido no mundo. É, também, muito expressiva a produção em outros países latino-americanos como México, Costa Rica e Honduras, e, no Extremo Oriente, na Indonésia e Tailândia. Os cinco principais importadores são Estados Unidos, Alemanha, Reino Unido, Bélgica/Luxemburgo e Japão.

No Brasil a bananeira é cultivada de Norte a Sul, tendo grande expressão econômica e elevado alcance social, sendo responsável por mais de 500 mil empregos diretos. É uma cultura versátil, cultivável em diferentes ambientes, produz o ano todo e auxilia na manutenção da fertilidade do solo, o que se caracteriza como um fator adicional de valor para sua produção por pequenos produtores.

No manejo pós-colheita tem sido buscado pelos produtores elementos que possam fixar a qualidade do produto com base em normas e padrões pré-estabelecidos. No Brasil a normalização para uma classificação que envolva qualidade vem sendo implementada pelo Programa Brasileiro para a Modernização da Agricultura, em processo liderado pela Ceagesp (MEDINA e PEREIRA, 2004). Soma-se à organização normativa a necessidade do desenvolvimento de ferramentas e métodos que possam auxiliar no processo de decisão e neste contexto buscou-se a sistematização de um método de análise com o uso de técnicas de segmentação e classificação de imagens, as quais viabilizaram respectivamente a detecção do aparecimento de manchas marrons ou padrões de injúrias e a separação em classes por estágios de amadurecimento.

As informações que podem ser obtidas com tais inferências constituem-se em indicadores de qualidade que estão relacionados aos processos de colheita e pós-colheita, ou seja, % de manchas marrons e cor da casca.

¹Engenheiro, Doutor em Automação, Pesquisador da Embrapa Instrumentação Agropecuária, São Carlos, SP, cruvinel@cnpdia.embrapa.br

²Engenheiro, Doutor em Físico-Química, Pesquisador da Embrapa Instrumentação Agropecuária, São Carlos, SP, herrmann@cnpdia.embrapa.br

³Fisiologista Vegetal, Mestre em Ciências Agrárias, Pesquisador da Embrapa Mandioca e Fruticultura, Cruz das Almas, BA, medina@cnpmpf.embrapa.br

O uso de imagens digitais⁴ para análise de qualidade de produtos tem sido cada vez mais frequente, inclusive no ambiente agropecuário (FAN et al., 1998; LEE e SLAUGHTER, 1998; STEWARD e TIAN, 1998; CRUVINEL et al., 1999; BASSET et al., 2000; SHRESTHA et al., 2001; HILST VAN DER e HOOP, 2005; XING et al., 2007; CRUVINEL, 2007).

Para se extrair informações de imagens digitais é necessário, inicialmente, dividi-la em partes ou objetos que a compõem. Este processo de segmentação pode ser formalmente definido pela identificação das regiões homogêneas de uma determinada imagem e das bordas ou limites dessas regiões. Essas regiões homogêneas são, na maioria dos casos, objetos e as bordas, seus contornos. Inúmeros algoritmos têm sido propostos para a segmentação de imagens digitais (OHLANDER et al., 1978; ZHANG, 1996; SHI e MALIK, 1997; SHAPIRO e STOCKMAN, 2001; OSHER e PARAGIOS, 2003; PANTOFARU e HEBERT, 2005) e, apesar da diversidade de ferramentas que se dispõem a realizar tal tarefa, todas utilizam, essencialmente um modelo de detecção de bordas e como principal diferença procedimentos que atendam às particularidades de cada aplicação. Dentre essas particularidades relacionam-se, entre outras, a homogeneidade dos objetos que constituem a cena (imagem), ou seja, quão definido é o fim de um objeto e início de outro, o grau de fidelidade entre a imagem analisada e a imagem original, e a fidelidade entre as bordas obtidas e as descontinuidades da imagem.

O modelo geral que tem sido utilizado para a segmentação de imagens digitais é uma variação do modelo de Mumford-Shah (MUMFORD e SHAH, 1985; MOREL e SOLIMINI, 1995), o qual foi proposto por Blake e Zisserman (HILTS VAN DER e HOOP, 2005).

O modelo de Mumford-Shah, define o problema de segmentação como um problema de homogeneidade na união das regiões (objetos) e detecção de borda. Assim, dada uma imagem representada pela função bidimensional, $f(x, y)$ o problema é caracterizado como sendo a busca simultânea pela imagem dividida em regiões suaves $u(x, y)$ e um conjunto K de descontinuidades bruscas, as bordas (contornos) de $f(x, y)$. Desta forma a melhor segmentação de uma dada imagem é obtida minimizando-se a função:

$$Seg[u(x, y), K] = g \int_K (|u(x, y)|^2 + [u(x, y) - f(x, y)]^2) dx dy, length(K) \quad (1)$$

onde o primeiro termo impõe que $u(x, y)$ seja suave no lado de fora das bordas, a segunda, que a imagem $u(x, y)$ de fato se aproxime da imagem original $f(x, y)$ e o terceiro termo, que o conjunto de descontinuidades (bordas) tenha um tamanho mínimo (e portanto, sejam tão suaves quanto possível). Algoritmos que minimizam a função acima têm como resultado rascunhos da imagem original, ou seja, imagens que dão a impressão de terem sido desenhadas.

Uma vez segmentadas as imagens digitais, utiliza-se técnicas de classificação que possibilitem o arranjo do resultado em classes cujos objetos ou elementos apresentem características semelhantes.

Neste trabalho utilizou-se a técnica de classificação de Bayes, que busca minimizar o risco para

teste de hipóteses. O risco de Bayes é definido, segundo Scharf (SCHARF, 1991; MASCARENHAS et al., 2000), como uma média da função de perda, p_{ij} que corresponde ao custo de classificar uma região como pertencente à classe i , sendo esta, na realidade, pertencente à classe j .

Sendo assim, a estratégia de decisão para a classificação consiste em minimizar a perda condicional média, dada por:

$$L_x w_j = \sum_{j=1}^m p_{ij} w_j | X \quad (2)$$

onde, $\{w_j, j = 1, \dots, m\}$ é o conjunto de m classes; X é a observação e $p_{w_j|X}$ é a probabilidade condicional da classe ser w_j dada a observação X .

A observação X é uma variável aleatória que representa os possíveis resultados do experimento. Podendo esta ser discreta ou contínua e será detalhada mais à frente.

Definindo o custo p_{ij} como uma função de perda simétrica (zero-um):

$$p_{ij} = \begin{cases} 0, & i = j \\ 1, & i \neq j \end{cases} \quad (3)$$

então (2) torna-se:

$$L_x w_j = \sum_{j=1}^m p_{w_j|X} \quad (4)$$

e $L_x w_j$ será mínimo quando a probabilidade a posteriori, $p_{w_j|X}$ for máxima.

Desse modo, a regra de decisão pode ser expressa por:

$$X = w_i \quad p_{w_i|X} = \max p_{w_j|X} \quad (5)$$

ou seja, para os custos dados em (5), a maior probabilidade a posteriori indica a classe a ser escolhida.

Partindo da equação (5), Lee e colaboradores (LEE et al, 1987) definem a função de adesão para um conjunto de n observações, ou seja, $X = x_1, \dots, x_n$. Deste modo tem-se que:

$$p_{w_j|X} = p_{w_j|x_1, \dots, x_n} \quad (6)$$

Mas $p_{w_j|X}$ pode ser escrito como:

$$p_{w_j|X} = \frac{p(X|w_j) p(w_j)}{p(X)} = \frac{p(x_1, \dots, x_n | w_j) p(w_j)}{p(x_1, \dots, x_n)} \quad (7)$$

onde $p(X|w_j)$ é a densidade condicional, $p(w_j)$ é a probabilidade a priori e $p(X)$ é dado por:

$$p(X) = \sum_{j=1}^n p(X|w_j) p(w_j) \quad (8)$$

O custo de classificação é baseado na regra de Bayes, que é utilizada para estimar a probabilidade condicional de uma determinada classe, a partir da qual é adotado um conjunto de restrições, como independência entre as observações (DUDA e HART, 1973), que decompõe esta probabilidade em produtos de probabilidades condicionais, tendo então:

$$p_{w_j|X} = p_{w_j} \prod_{k=1}^n \frac{p(x_k|w_j)}{p(x_k)} \quad (9)$$

Como $p_{w_j|X} = \frac{p_{w_j|X} p(X)}{p(X)}$, então a Função de

Adesão é definida como:

⁴Em termos computacionais uma imagem digital pode ser descrita por um conjunto de elementos de área denominados como Pel ou Pixel, ou ainda *Picture element* com coordenadas (x, y) , espacialmente distribuídos e com intensidades $f(x, y)$ definidas por números reais em função do brilho, de pseudo-cores ou dos níveis de cinza utilizados para efeito de calibração.

$$p w_j | X = p w_j^{1-n} \prod_{k=1}^n p w_j | X \quad (10)$$

Dentre as condições assumidas pela regra de Bayes, além da independência entre as observações, assume-se que todas as observações têm o mesmo peso, ou seja, influenciam igualmente no resultado (GARG e ROTH, 2001).

Esta última condição vem sendo questionada, uma vez que entre um conjunto de observações pode haver observações “não-confiáveis”, como observações ruidosas, por exemplo.

Como solução, vem sendo proposta a adoção de graus de confiança das observações, que devem atuar de maneira tal que quando a confiança de uma observação é baixa, o efeito desta no resultado final seja diminuído e quando a confiança de uma observação é alta, seu efeito é realçado (MÁXIMO e FERNANDES, 2003).

O método foi desenvolvido considerando módulos para recepção e aquisição de imagens, segmentação, classificação e diagnóstico para auxílio à tomada de decisão, análise visual e modelagem matemática para auxiliar na análise de estruturas reconhecidas em imagens de bananas. Como ferramenta de implementação foi utilizada a linguagem C++ da Borland®.

Para a aquisição de imagens de bananas foi utilizado uma câmara fotográfica do tipo Canon Tipo LH-DC10 (8 MegaPixel PowerShot Pro 1) e ambiente com iluminação controlada em 900 Lx⁵. O método de análise de injúrias em bananas com visão computacional possui basicamente três *menus* principais, conforme ilustra a Figura 1.

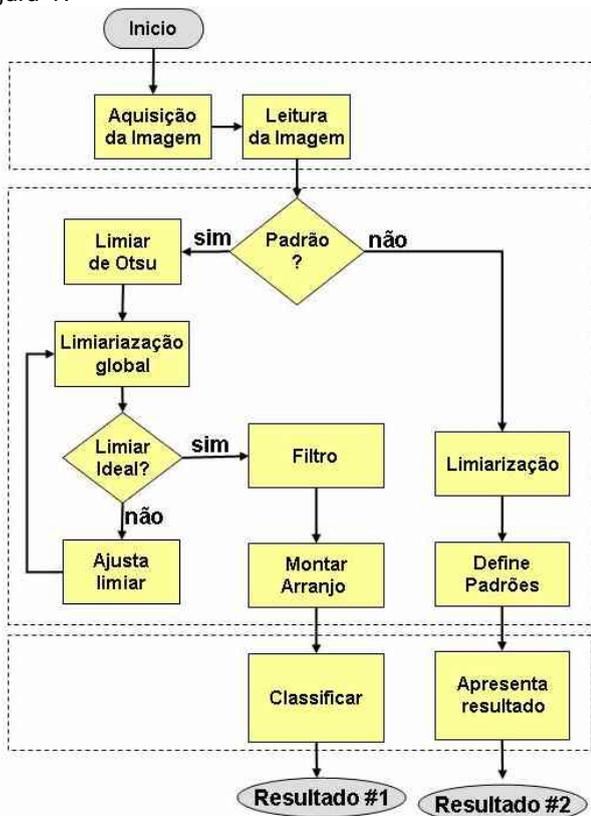


Fig. 1 - Estrutura principal de origem dos menus em três níveis.

⁵Lux (abreviadamente Lx) é a unidade de medida de iluminamento que mede a incidência perpendicular de 1 lúmen em uma superfície de 1 metro quadrado; 1 Lx equivale a 0,0929 lúmens.

Para validação foram consideradas diferentes situações de banana-prata (ou banana anã-grande, *Musa cavendishii* var. prata), a qual tem fruto reto de até 15 cm de comprimento, casca amarelo-esverdeada, em cachos, tanto na condição verde como maduras. Neste Comunicado Técnico são ilustradas situações que possibilitam a intervenção do especialista para a observação de uma estrutura de uma injúria na fruta, ou ainda uma caracterização de um outro acontecimento como doenças ou características de manejo e manuseio decorrente de colheita, transporte ou armazenamento. Assim, foram considerados os casos:

Cacho de *Musa cavendishii* (Banana Prata) com 8 bananas verdes e maduras;

Cacho de *Musa cavendishii* (Banana Prata) com 8 bananas contendo relevante injúria devido à transporte e armazenamento.

As análises foram feitas considerando as etapas de aquisição das imagens, seu pré-processamento, sua segmentação e classificação com inferência Bayesiana.

1- Primeiro Caso de estudo com Cacho de *Musa cavendishii* var. prata com 8 bananas misturando bananas verdes e maduras:

Neste estudo de caso foram observadas em um mesmo cacho bananas verdes, em amadurecimento e maduras, bem como manchas marrons nas cascas, decorrentes de diferentes fontes. O método de visão computacional viabilizou a verificação supervisionada dessas injúrias sofridas pela fruta, bem como possibilitou avaliar diferentes estados de amadurecimento.

A Figura 2 ilustra a interface de trabalho com áreas específicas para a imagem de entrada e para a imagem processada com a informação para o auxílio à tomada de decisão. Neste resultado é apresentado um histograma da imagem de entrada, o qual ilustra as ocorrências das diferentes tonalidades no objeto de análise.

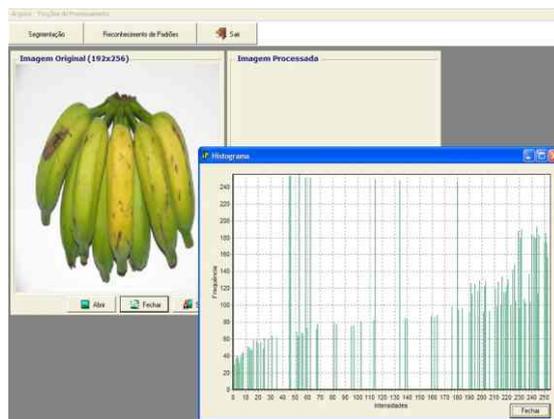


Fig. 2 - Interface de trabalho com áreas específicas para a imagem de entrada (cachos de *Musa cavendishii* var. prata com 8 bananas misturando bananas verdes e maduras) e para a imagem processada com a informação para auxílio à tomada de decisão.

Na Figura 3 é apresentada a seleção da intensidade de pixel que foi identificada automaticamente, a qual neste caso foi centrada na tonalidade apresentada em um dos pontos de injúria. O próprio usuário seleciona computacionalmente (com o próprio mouse do sistema) o ponto de injúria a ser utilizado.




Fig. 3 - Seleção da intensidade de pixel a ser identificada automaticamente, a qual neste caso foi centrada na tonalidade apresentada em um dos pontos de injúria.

Na Figura 4 é apresentada a imagem resultante com a identificação automática das regiões que apresentaram problemas, ou seja % de manchas marrons no cacho sob análise.




Fig. 4 - Imagem resultante com a identificação automática das regiões que apresentam problemas.

A Figura 5 ilustra o uso do classificador de Bayes que diferencia os diferentes estágios de amadurecimento das bananas.




Fig. 5 - Uso de classificador de Bayes para diferenciar os diferentes estágios de amadurecimento das bananas.

2- Caso com Cacho de *Musa cavendishii* var. prata com 8 bananas contendo injúria devido à transporte e armazenamento:

Neste estudo de caso foram observadas em um mesmo cacho bananas que sofreram injúria devido a processo de transporte e armazenamento. A Figura 6 ilustra a imagem de entrada com o seu respectivo histograma, o qual ilustra as ocorrências das diferentes tonalidades no objeto de análise, com presença acentuada de ocorrência de pixels em regiões de média intensidade.

Na Figura 7 é apresentado o resultado da operação de segmentação com base em limiarização RGB, cujos valores de referência em função das componentes fundamentais foram tomados como R = 114, G = 104 e B = 92, com tolerância de 35. É importante observar que a paleta para cada componente se encontra na faixa de [0 a 255] e que uma vez estabelecida a seleção as regiões de interesse são identificadas automaticamente para o auxílio à tomada de decisão.

Na Figura 8 é apresentado a classificação automática das regiões de injúrias, o que, conforme observado, auxilia na inferência de um indicador qualitativo e outro quantitativo sobre o % de manchas no cacho analisado.




Fig. 6 - Interface de trabalho com áreas específicas para a imagem de entrada (cachos de *Musa cavendishii* var. prata com 8 bananas contendo injúria devido à transporte e armazenamento), área para a imagem processada e histograma com presença acentuada de ocorrência de pixels em regiões de média intensidade.




Fig. 7 - Resultado da operação de segmentação com base em limiarização RGB, cujos valores de referência em função das componentes fundamentais foram tomados como R = 114, G = 104 e B = 92, com tolerância de 35 em região de injúria.




Fig. 8 - Uso de classificador de Bayes para identificar classes que representam injurias nas bananas.

O método apresentado encontra aplicação na identificação da formação de estruturas de manchas marrons ou injúrias em bananas e seu estado de amadurecimento. O uso de processamento digital de imagens se mostrou útil e eficaz no auxílio ao diagnóstico qualitativos e quantitativos para o processo de análise.

Referências

- BASSET, O.; BUQUET, B.; ABOUELKARAM, S.; DELACHARTRE, P.; CULIOLI, J. Application of Texture Image Analysis for the Classification of Bovine Meat. *Food Chemistry*, London, n. 69, p. 437-445, 2000.
- CRUVINEL, P. E. New sensors for quality monitoring in precision agriculture In: INTERNATIONAL SYMPOSIUM ON PRECISION AGRICULTURE, 2007, Viçosa, MG, 2007. [S. l.: s. n., 2007.].
- CRUVINEL, P. E.; VIEIRA, S. R.; CRESTANA, S.; MINATEL, E. R.; MUCHERONI, M. L.; TORRE-NETO, A. Image processing in automated measurements of raindrop size and distribution. *Computers and Electronics in Agriculture*, Amsterdam, p. 205-217, 1999.
- DUDA, R.; HART, P. E. *Pattern Classification and Scene Analysis*. New York: John Wiley & Sons, 1973.
- FAN, G.; ZHANG, N.; PETERSON, D. E.; LOUGHIN, T. M. Real-time weed detection using machine vision. The 1998 ASAE ANNUAL INTERNATIONAL MEETING, Orlando, Florida. [S. l.: s.n.], 1998. 17 p. Paper n. 98032.
- GARG, A.; ROTH, D. Understanding Probabilistic Classifiers. In: THE EUROPEAN CONFERENCE ON MACHINE LEARNING, ECML, 2001. [S. l.]: University of Illinois, USA, 2001.
- GOMES, J. A **Absorção de nutrientes pela bamaneira cv prata em diferentes estágios de desenvolvimento**. Piracicaba, 1988. Dissertação (Mestrado) - Escola Superior de Agricultura "Luiz de Queiróz", Universidade de São Paulo, Piracicaba.
- HILST VAN DER, R. D.; HOOP, M. V. Banana-doughnut kernels and mantle tomography. *Geophysics Journal*, [S. l.], v. 163, p. 956-961, 2005.
- IBRAF- INSTITUTO BRASILEIRO DE FRUTAS, 2007. Disponível em: <<http://www.ibraf.org.br/>>. Acesso em: 12 dez. 2007.
- LEE, T.; RICHARDS, J. A.; SWAIN, P. H. Probabilistic and evidential approaches for multisource data analysis. *IEEE Transactions on Geoscience and Remote Sensing*, New York, v. 1, GE-25, n. 3, p. 283-293, 1987.
- LEE, W. S.; SLAUGHTER, D. C. Plant recognition using hardware-based neural network. In: ASAE ANNUAL INTERNATIONAL MEETING, Orlando, Florida, 1998. [S. l.: s. n.], 1998. 14 p. Paper n. 983040.
- MASCARENHAS, N. D.; CRUVINEL, P. E.; HOMEM, M. R. P. The linear attenuation coefficients as features of multiple energy CT image classification. *Nuclear Instruments and Methods in Physics Research*, Amsterdam, v. 452, n. A, p. 35 360, 2000.
- MÁXIMO, O. A.; FERNANDES, D. Uso de graus de confiança das classes em Classificadores Bayesianos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte. [S. l.: s.n., 2003].
- MEDINA, V. M.; PEREIRA, M. E. C. Pós Colheita In: BORGES, A. C.; SOUZA, L. S. (Ed.). **O Cultivo da Bananeira**. Cruz das Almas BA: Embrapa Mandioca e Fruticultura, 2004. 279 p. ISBN 857158010-3.
- MOREL, J. M.; SOLIMINI, S. **Variational Methods in Image Segmentation**. Boston: Birkhauser, 1995. 245 p. (Progress in Nonlinear Differential Equations and Their Applications, v. 14).
- MUMFORD, D.; SHAH, J. Boundary detection by minimizing functionals. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 1985, San Francisco. [S. l.: s.n., 1985].
- OHLANDER, R.; PRICE, K.; REDDY, D. R. Picture Segmentation Using a Recursive Region Splitting Method. *Computer Graphics and Image Processing*, New York, v. 8, p. 313-333, 1978.
- OSHER, S.; PARAGIOS, N. **Geometric Level Set Methods in Imaging Vision and Graphics**. [S. l.]: Springer Verlag, 2003. ISBN 0387954880.
- PANTOFARU, C.; HEBERT, M. **A Comparison of Image Segmentation Algorithms**. [S. l.]: Robotics Institute, Carnegie Mellon University, 2005. (tech. report CMU-RI-TR-05-40).
- SCHARF, L. L. **Statistical signal processing: detection, estimation, and time series analysis**. [S. l.]: Addison-Wesley, 1991.
- SHAPIRO, L. G.; STOCKMAN, G. C. **Computer Vision**. New Jersey: Prentice-Hall, 2001. p. 279-325. ISBN 0-13-030796-3.
- SHI, J.; MALIK, J. Normalized Cuts and Image Segmentation. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 1997, [S. l.]. [S. l.: s.n., 1997]. p. 731-737.

SHRESTHA, B. P.; NAGATA, M.; CAO, Q. Study on Image Processing for Quality Estimation of Strawberries. (Part 1). Detection of Bruises on Fruit by Color Image Processing. **Journal of Society of High Technology in Agriculture**, [S. l.], v. 13, n. 2, p. 115-122, 2001.

STEWART, B. L.; TIAN, L. F. Real-time machine vision weed-sensing. In: ASAE ANNUAL INTERNATIONAL MEETING, 1998, Orlando, Florida. [S. l.: s.n., 1998]. 17 p. Paper n. 983033.

TWFORD, I. T. Banane nutrition : a review of principles and practices. **Journal of The Science of Food and Agriculture**, London, v. 18, n. 5, p. 177-83, 1967.

XING, J.; SAEYS, W.; BAERDEMAEKE, J. Combination of chemometric tools and image processing for bruise detection on apples. **Computers and Electronics in Agriculture**, Amsterdam, v. 56, n. 1, p. 1-13, 2007.

ZHANG, Y. J. A survey on evaluation methods for image segmentation. **Pattern Recognition**, Ezmsford, v. 29, n. 8, p. 1335-1346, 1996.

Comunicado Técnico, 83

Ministério da Agricultura,
Pecuária e Abastecimento

Exemplares desta edição podem ser adquiridos na:

Embrapa Instrumentação Agropecuária
Rua XV de Novembro, 1542 - Caixa Postal 741
CEP 13560-970 - São Carlos-SP

Fone: 16 3374 2477

Fax: 16 3372 5958

E-mail: sac@cnpdia.embrapa.br
www.cnpdia.embrapa.br

1a. edição

1a. impressão 2007: tiragem 300

Comitê de Publicações

Presidente: *Dr. Carlos Manoel Pedro Vaz*
Membros: *Dra. Débora Marcondes B. P. Milori,*
Dr. João de Mendonça Naime,
Dr. Washington Luiz de Barros Melo,
Valéria de Fátima Cardoso

Membro Suplente: *Dr. Paulo S. P. Herrmann Junior*

Expediente

Revisor editorial: *Dr. Victor Bertucci Neto*
Normalização bibliográfica: *Valéria de Fátima Cardoso*
Tratamento das ilustrações: *Valentim Monzane*
Editoração eletrônica: *Valentim Monzane*