

# UN SISTEMA DE VISIÓN PARA LA DETECCIÓN DE DEFECTOS

*Santiago Candela, Jose A. Muñoz, Francisco Alayon, Carmelo Garcia*  
*Departamento de Informática*  
*Universidad de Las Palmas de Gran Canaria*  
*Las Palmas de G.C, España.*

**ABSTRACT:** This work make a description of techniques and algoritms to define a general strategy to attack the problem of visual automatic detection of defects, based on Systems Theory and Artificial Vision techniques, wich allows for a transportability to defects detection problems on several materials like leather, wood, clothes and plastics.

**KEYWORDS:** Artificial Visión, Fault Detection, Texture Analysis.

## 1. INTRODUCCIÓN.

El problema de la detección de defectos aparece en numerosos procesos de fabricación industrial, como un aspecto del control de calidad, por lo que es una faceta fundamental en la automatización de las cadenas de producción. Esto justifica el esfuerzo que últimamente se está realizando en la investigación de técnicas para tal fin.

Cuando nos enfrentamos al problema de la detección de defectos debemos plantearnos, como primer paso en la resolución del problema, el encontrar un marco teórico de trabajo que nos permita plantear y formalizar nuestro problema. Para ello el saber responder a la cuestión *¿Qué se entiende por defecto?* es vital. Aunque en muchos casos, y debido a la alta capacidad de proceso del ser humano, esta respuesta parece sencilla, hoy día desde un punto de vista formal no disponemos de tal respuesta, y por lo tanto, ni mucho menos de un marco teórico general donde abordar de forma analítica este problema.

En este trabajo describimos la estrategia general que hemos diseñado para resolver el problema de la detección automática de defectos en pieles curtidas de animales como cerdo y vaca, y que se utilizan en la industria peletera. Un primer paso consiste en definir que se entiende por defecto, para ello observamos que las imágenes digitalizadas de pieles presentan una cierta uniformidad en su textura, donde la presencia de un defecto se manifiesta como un cambio de textura o una alteración de la uniformidad. Con este planteamiento, el problema de la detección de fallos se transforma en encontrar los cambios de uniformidad o periodicidad en la textura.

## 2. DESCRIPCIÓN DEL PROBLEMA.


Nuestro objetivo es poder detectar defectos en pieles de animales a partir de las imágenes digitalizadas adquiridas mediante un sistema cámara-computador. Estudiado un amplio muestrario de pieles con defectos, se observa lo siguiente acerca de la apariencia de las zonas defectuosas:

- a. Los fallos se manifiestan como cambios estructurales o como cambios tonales.
- b. Para un mismo tipo de fallo la intensidad del cambio estructural o tonal con respecto a zonas buenas no siempre es la misma.
- c. Incluso en zonas buenas de piel se producen variaciones tonales y estructurales muy suaves.

Dadas estas observaciones, el contestar a la pregunta ¿Cual es el conjunto óptimo de descriptores que nos permiten distinguir y discriminar entre zona buena y zona defectuosa? no tiene fácil respuesta, pues nos encontramos con que tal caracterización es borrosa. Esto va a obligarnos a realizar distintos procesos eurísticos para encontrar una solución al problema.

### 3. ESTRATEGIA GENERAL.

En este apartado describimos la estrategia general a que hemos llegado, tras la realización de distintas pruebas y que seguimos para resolver el problema. Esta estrategia presenta la ventaja de ser independiente del tipo de material y defecto por lo que es susceptible de ser utilizada en la detección de defectos en otros materiales tales como: madera, telas, plásticos, etc. Nuestra propuesta de esquema está formado por las siguientes etapas:



1. Adquisición de la imagen a analizar.
2. Preproceso de la imagen
3. Obtención de descriptores.
4. Cálculo de la imágenes de diferencias.
5. Toma de decisión.

Fig.1 Estrategia General

#### Fase 1: Adquisición de la imagen a analizar.

Debido a la naturaleza de nuestro problema captamos las imágenes con una cámara de estado sólido CCD de alta resolución de 1024x1024 pixels, donde cada punto posee un nivel de gris que varía en un rango de 0 a 255. Esta imagen es introducida en el computador mediante una placa de adquisición, almacenamiento y presentación monocroma.

Un aspecto importante relacionado con esta fase son las condiciones luminosas ambientales. Debido a la sutileza visual con que se manifiestan los defectos es primordial que sobre toda la superficie de la piel a adquirir, incida una intensidad luminosa uniforme, pues de lo contrario se pueden inducir defectos no existentes realmente. Otros aspectos importantes que se han puesto de manifiesto en nuestras experiencias es la mejor o peor visualización del defecto en función del tipo de luz empleada y de la dirección de haz de luz incidente.


## Fase 2: Preproceso de imagen.

Esta etapa tiene por finalidad, por un lado, lograr la mejora de la imagen a analizar; frente a ruidos o leves variaciones de luz en la fase anterior, y por otro lado, enfatizar los fallos que tiene la piel a analizar; de esta manera se facilita la detección de los defectos.

Entre los preprocesos ensayados uno que ha proporcionado buenos resultados es el conocido por "*proceso facilitador*". Básicamente, se trata de un proceso inspirado en trabajos previos [16] sobre procesamiento retinal de imágenes. Este consiste en evaluar una imagen transformada,  $R(x,y)$ , como:

$$R(x,y) = C(x,y)*P(x,y) - Q(x,y)$$


Siendo  $(x,y)$  las coordenadas de un punto en la imagen;  $C(x,y)$  una zona de la imagen original que llamamos centro, alrededor del punto  $(x,y)$ ;  $P(x,y)$  otra zona de la imagen original, envolvente de la zona centro  $C$ , llamada periferia; y por último,  $Q(x,y)$  una función umbral canceladora de ruido.



Otro preproceso que proporciona buenos resultados es el "filtrado paso alto no lineal facilitado por la desviación típica" ya que pequeños cambios locales en la textura y aumento de la desviación típica van en la misma dirección para indicar variaciones en la textura. Básicamente este filtrado consiste en obtener la imagen transformada,  $R(x,y)$ , definida como:

$$R(x,y) = \text{Abs}(E_v - I(x,y)) * S_v$$

Siendo  $(x,y)$  las coordenadas de un punto en la imagen;  $E_v$  la media tonal de una ventana entorno al punto de imagen;  $I(x,y)$  valor tonal en la imagen original;  $S_v$  la desviación típica tonal de la ventana entorno al punto de imagen; y  $\text{Abs}$  es la función valor absoluto (exclusive OR detección de contornos).



Fase 3: Cálculo de descriptores.

En esta fase se calculan los descriptores en ventanas de la imagen, de tamaño fijo, para posteriormente proceder al etiquetado de cada una de ellas como zona buena o defectuosa. Para esto se utiliza un tipo de convolución generalizada [4] sobre la imagen preprocesada, tal que para cada pixel, se definen unos vecinos (el dominio del punto), donde el núcleo de la convolución computa una serie de reglas para obtener un vector de propiedades. Como resultado, obtenemos una serie de imágenes de parámetros, las cuales obviamente muestran el efecto de bordes de toda convolución.

La convolución generalizada puede presentar un coste computacional elevado, tal que para cada caso, es necesario evaluar los requerimientos de computo versus la efectividad del algoritmo. Esta evaluación requiere una serie de cuidadosos test. Diferentes grupos de test se han realizado degradando la "resolución" de la convolución, de forma que se ha ensayado distintos saltos de la posición del pixel central, 2, 4, 16. Los mejores resultados se obtienen para saltos de 1, ya que este proporciona una continuidad

en la imagen, si bien el coste computacional es mayor.

Se ha empleado un amplio abanico de núcleos para la obtención de descriptores de los que destacamos los siguientes:

a. Estadísticos de primer orden [13]: Este conjunto de estadísticos lo constituyen todos aquellos que se obtienen a partir de la distribución de frecuencias de los niveles de gris, este es el caso de la media, varianza, energía, entropía, kurtosis, y apuntamiento.

b. Estadísticos de segundo orden [3] y [18]: Este conjunto de descriptores se obtienen a partir de la matriz de coocurrencia. Este es el caso de inercia, energía, entropía, y homogeneidad local.

c. Parámetros espectrales [7]: Estos descriptores se obtienen en función de los armónicos contenidos en distintas bandas de frecuencias espectrales. Este es el caso de las sumatorias del espectro de potencia para distintas distancias radiales.

d. Respuesta ante núcleos sensitivos de frecuencia: Estos descriptores se obtienen a partir de la respuesta ante distintos núcleos que filtran distintos cambios de frecuencia en los niveles de gris.

e. Respuesta ante núcleos topológicos [9]: Estos descriptores se obtienen a partir de la respuesta ante núcleos que enfatizan propiedades topológicas en la imagen.

#### Fase 4: Cálculo de la imagen de diferencias.

En esta fase se calcula para cada descriptor una imagen de diferencias o distancias, donde éstas se calculan de la siguiente manera:

$$d(x,y) = (D(x,y) - D_p(x,y))/\text{Min}[D(x,y),D_p(x,y)]$$

Siendo  $(x,y)$  un punto de la imagen,  $D(x,y)$  el valor del descriptor en una ventana central en el entorno del punto,  $D_p(x,y)$  el valor del descriptor en una zona periférica ocho ventanas alrededor del punto.

#### Fase 5: Regla de decisión.





Una vez obtenida la imagen de diferencias para cada parámetro, se procede en esta fase a etiquetar cada ventana de imagen como zona buena o zona defectuosa.


La regla de decisión que se utiliza es:

"Si" (  $d(x,y) > U$  ) "Entonces"  
    Zona defectuosa  
"Si no"  
    Zona buena  
"Fin si"

Siendo  $U$  un valor umbral característico de cada descriptor.

A continuación se presentan ejemplos donde se ha utilizado como núcleo para la obtención de descriptores los estadísticos de primer orden. La imagen de la izquierda representa la imagen original, y la derecha la imagen resultado con los defectos marcados en negro y la zona buena en blanco.





## CONCLUSIONES

La detección automática de defectos en pieles curtidas, utilizando un sistema automático de visión es difícil debido a que el proceso humano de detección es multisensorial (contacto manual de la piel, junto con distintas observaciones visuales) y también por que algunos defectos (los cuales no pueden predecirse con anterioridad) necesitan de unos requerimientos de iluminación especiales para ser vistos por un sistema camara-ordenador. Sin embargo, familias de defectos pueden ser detectados e identificados utilizando algoritmos relativamente fáciles y rápidos.

## AGRADECIMIENTOS

Los autores quieren expresar su agradecimiento al Profesor y Maestro Roberto Moreno Díaz por su dirección y aporte de ideas en el trabajo, parte del cual se ha realizado bajo el Proyecto Brite 2195.

## BIBLIOGRAFÍA

- [1] Amelia C. Fong, Lionel M. Ni, Kwan Y. Wong "Fast Discrimination Between Homogeneous and Texture Regions"
- [2] Borghesi, V. Cantoni, M. Diani."An Industrial Application of Texture Analysis".
- [3] Calvin C. Gotlieb, Helbert E. Kreyszig."Texture Descriptors Based on Co-Occurrences Matrices". Computer Vision, Graphics, and Image Processing. Academic Press, Inc. 1990.
- [4] Candela, S. Transformaciones de Campo Receptivo Variable en Proceso de Imágenes y Visión Artificial. Tesis Doctoral. Nov 1987.
- [5] Conners, R. Identifying and Locating Surface Defects in Wood: Part of an Automated Lumber Processing System. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.Pami-5, No 6, November 1983.
- [6] D'Astous and M. E. Jernigan."Texture Discrimination Based On Detailed Measures Of Power Spectrum". IEEE. 1984.
- [7] Eklundh, J. O."On The Use of Fourier Features for Texture Discrimination". Computer Graphics and Image Processing. 1979.
- [8] Haralick, R. Statistical and Structural Approaches to Texture. Proceedings of the IEEE, vol 67, no 5, May 1979.
- [9] Haralick, R. Ridges and Valleys on Digital Images. Computer Vision, Graphics and Image Processing 22, 28-38, 1983.
- [10] Kiryati, N.; and D. Maydan. "Calculating Geometric Properties From Fourier Representation". Pattern Recognition. 1989.
- [11] Lowitz, G. Images, Principis, Traitements et Applications. Session Extraordinaire de L'ecole Internationale D'informatique AFCET. Abril 1983.
- [12] Muñoz Blanco, J. A."Jerarquización de estructuras de nivel bajo y medio para reconocimiento visual. Aplicaciones a texturas y formas. Tesis Doctoral. 1987.
- [13] Rao, K., Ahmed, N. Orthogonal Transforms for Digital Signal Processing. IEEE International Conference on Acoustics, Speech and Signal Processing P 136-40, 1976.
- [14] Richard W. Conners and Charles W. McMillin. "Identifying and Locating Surface Defects in Wood: Part of an Automated Lumber Processing System".IEEE Transactions on Pattern Analysis and Machine Intelligence.1983
- [15] Ronsin, D. Barba, S. Rabisson. "Comparision between Co-Occurrence Matrices, Local Histograms and Curvilinear Integration for Texture". Architectures and Algorithms for Digital Image Processing. SPIE. 1985.
- [16] Santana, O., Candela, S., Moreno-Diaz, R. Computer non-linear and Algorithmic Simulation of Static Retinal Processes. 6th International Congress of Cybernetics and Systems. Paris. 1984.
- [17] Steven W. Zucker, Demetri Terzopoulos."Finding Structure in Co-Occurrence Matrices for Texture Analysis".Image Modeling. Academic Press, Inc. 1981
- [18] Unser, M., Coulon, F. Detection of Defects by Texture Monitoring in Automatic Visual Inspection. Proceedings of The 2nd International Conference on Robot Vision and Sensory Controls November 1982. Stuttgart, Germany.
- [19] Wang, Li; D. C. He. "A new statistical approach for texture analysis". Photogrammetric Engineering and Remote Sensing, vol. 56, Nº 1, pp 61-66. 1990.
- [20] Wang, L.; and D. He. "Texture Classification Using Texture Spectrum". Pattern Recognition". 1990.
- [21] Weszka, J. S.; Dyer and A. Rosenfeld."A Comparative Study of Texture Measures for Terrain Classification. IEEE Transaction On Systems, Man, and Cybernetics. 1976.
- [22] Young Won Lim, Sang Uk Lee "On The Color Image Segmentation Algorithm Based on the Thresholding and the Fuzzy C - Mean Techniques. Pattern Recognition.1990