

DISCRIMINACIÓN DE TEXTURAS EN IMÁGENES INALÁMBRICAS, UTILIZANDO EL ALGORITMO K-MEANS

Discrimination of textures in wireless images using the K-means algorithm

Pineda-Torres, F.*; Molina-Sanches, S.J.** y Afanador-Montañez, L.E.***.



RESUMEN

La clasificación de texturas sigue siendo uno de los principales retos del procesamiento de imagen. Imágenes y video que ahora son enviados de forma inalámbrica, y pese a la capacidad del ancho de banda y perturbaciones, deben contener sólo la información esencial de la escena con baja resolución y baja densidad de píxeles en la escala de grises sobre su histograma. De la imagen transmitida y su respectiva matriz de co-ocurrencia se generan algunos descriptores estadísticos de segundo orden. Los espacios tridimensionales con la energía, el contraste y la homogeneidad, son determinantes sobre el análisis y la adecuación del algoritmo de k-means, cuyos valores de centroides son ubicados para la respectiva discriminación de las texturas. El Código funcional dentro del software de Matlab® toolbox image processing y su adecuación inalámbrica sobre la banda transportadora por medio de la tarjeta Raspberry Pi, permite la separación de los elementos discriminados dentro del sistema.

Palabras clave: centroide, k-means, matriz de co-ocurrencia, microcontrolador, procesamiento de imagen.

ABSTRACT

Texture segmentation remains one of the major challenges in image analysis. Video and Images that are currently sent wirelessly and despite the capacity of bandwidth and disturbances they must contain only the essential information of the scene with low resolution and low density of pixels in the gray scale on the histogram. Some second order statistical descriptors are generated of the transmitted image and their respective co-occurrence matrix; three-dimensional spaces with energy, contrast and homogeneity, are crucial for the analysis and adaptation of k-means algorithm, the values of centroids are located for the respective discrimination of textures. Functional code in the Matlab software and the toolbox of image processing and wireless adjustment on the conveyor belt through the Raspberry Pi card, it allows the separation of the elements within the system.

Key words: centroid, k-means algorithms, co-occurrence matrix, microcontroller, image processing.

* Ingeniero Electrónico, Especialista en Automática e Informática Industrial; Universidad Autónoma de Colombia. Magister en Ingeniería Electrónica y de Computadores, Universidad de los Andes. franklin.pineda@fuac.edu.co

** Ingeniero Electrónico, Universidad Autónoma de Colombia. santiagomolina003@hotmail.com

*** Ingeniero Electrónico, Universidad Autónoma de Colombia. luis.afanador@fuac.edu.co

1. INTRODUCCIÓN

El desarrollo tecnológico de los últimos 20 años ha popularizado los gráficos por computadora y el procesamiento de la imagen (Gil, 2008). Por supuesto la carga computacional que esfuerza en tener diferentes imágenes de texturas en procesamiento directo, lo que hace que sea necesario computadoras con procesadores rápidos a volúmenes altos de información.

La textura provee de significado a las superficies: «ella contiene información importante acerca del ordenamiento estructural y sus relaciones con el ambiente que la rodea» (Jensen-Gil, 2008). La síntesis de la textura (Forsyth y Ponce, 2003) y sus métodos de análisis estructurales, estadísticos y espectrales (Universidad Rey Juan Carlos, 2015) cuantifican las superficies con base en descriptores de texturas (Haralick, 1973). Sus 14 descriptores no descienden de los estadísticos de primer orden, los cuales trabajan sobre el histograma, sino que se encuentran basados en los estadísticos de segundo orden con la matriz de co-ocurrencia. La matriz de co-ocurrencia es un resumen de la forma en que los valores de los píxeles ocurren al lado de sus píxeles vecinos (Presutti, 2004). Dentro de los descriptores más utilizados se encuentran: la energía que mide el grado de homogeneidad local en la imagen, el contraste como grado de luminosidad y la correlación como grado de similitud entre píxeles a escala de grises (Perez, 2008). Aunque no siempre esta tríada puede discriminar todo tipo de texturas. Para el caso del proyecto donde se desea clasificar madera, ladrillo e icopor, este espacio tridimensional se adecua perfectamente para aplicar el algoritmo de k-means.

El problema del agrupamiento puede definirse como *particionar n puntos de un espacio n -dimensional en k grupos*, atendiendo a una similitud entre los puntos. Dentro de los algoritmos de agrupamiento no paramétricos se encuentran los particionales (Pascual, 2015)

donde reside el algoritmo k-means (Mac Queen, 1967). Éste asume, al igual que todos los algoritmos *particionales*, un conocimiento *a priori* del número de clusters. La idea general es poder generar clusters por cada textura presentada, de esa forma cada vez que se presente una textura, ésta se enlace directamente al agrupamiento correspondiente debido a una similitud. En nuestro caso, los descriptores estadísticos de segundo orden. El procesamiento de texturas ha sido utilizado ampliamente en las industrias satelital, ambiental, textil (Fernández, 2015), médica (Caicedo, 2006; Sutton, 1972) y académicamente latente casi en todos los campos de las ciencias e ingenierías.

2. MÉTODO

2.1. Descripción general

En la figura 1 se observa una descripción general del funcionamiento del proyecto: a través de un computador se controla inalámbricamente una banda transportadora (servomecanismo) que lleva incorporada una cámara web donde se tiene una imagen de video en tiempo real conectada a la tarjeta raspberri encargada de la comunicación wi-fi entre todo el conjunto de elementos de la banda transportadora (luz, cámara, selector y motor) y una interfaz de usuario realizada en el software Matlab.

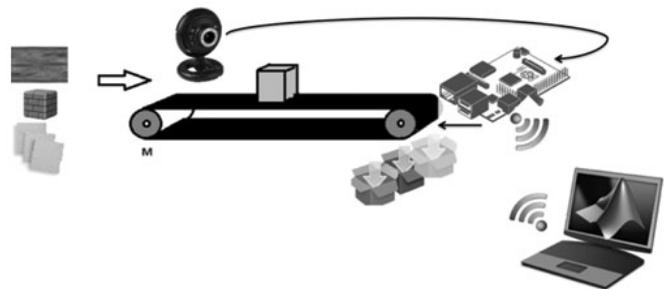


Figura 1. Descripción General

El sistema responde a tres fases:

- Adquisición del video: la textura debe recorrer la banda transportadora hasta llegar al punto donde es capturada por la cámara para obtener la imagen de la textura que es enviada al computador por medio de una comunicación wi-fi.
- Procesamiento de la imagen: usando el *toolbox image processing* se desarrolla un algoritmo que combina técnicas de preprocesado, y k-means para la identificación de la textura. El software envía posteriormente una señal a la banda indicando el tipo de textura ingresado.
- Clasificación de la textura: luego de enviar la señal a la banda transportadora del tipo de textura encontrado se activa un mecanismo en la banda-selector por servomotor para ubicar adecuadamente la textura a clasificar.

2.2. Técnicas de procesamiento espacial

Los métodos estadísticos de segundo orden proponen un histograma de dos dimensiones debido a que consideran propiedades en pares de pixeles.



Figura 2. Texturas: a) Icopor b) Madera c) Ladrillo

3.1. Descriptores texturales

Haralick propone 14 descriptores de texturas; los cinco más sobresalientes para la caracterización de las texturas: la energía (Ene) (1), la entropía (Ent) (2), el contraste (Con) (3), la correlación (Cor) (4) y la homogeneidad (Hom) (5).

$$Ene = \sum_i \sum_j Nd^2(i,j) \tag{1}$$

$$Ent = \sum_i \sum_j Nd \ln (Nd (i,j)) \tag{2}$$

$$Con = \sum_i \sum_j (i - j)^2 Nd (i,j) \tag{3}$$

$$Cor = \frac{\sum_i \sum_j (i - \mu_i)(j - \mu_j) Nd (i,j)}{(\sigma_i \sigma_j)} \tag{4}$$

$$Hom = \sum_i \sum_j \frac{Nd(i,j)}{(1 + ||i - j||)} \tag{5}$$

Donde μ_i , μ_j corresponden a la media y σ_i , σ_j a la desviación estándar para las filas y las columnas de $Nd(i,j)$.

Tabla 1. Estadísticos de II Orden para las imágenes de la figura 2 -a), b), c).

Estadístico	Imagen a)	Imagen b)	Imagen c)
Energía	0.001903	0.0008049	0.0011095
Entropía	3.652908	3.642908	3.635609
Contraste	17.540473	28.7556698	35.4288919
Correlación	0.996037	0.9982047	0.9953198
Homogeneidad	0.425319	0.3767020	0.3451771

Fuente: propia

3.2. Matriz de co-ocurrencia

El método más utilizado para medir matemáticamente la textura es la matriz de co-ocurrencia de niveles de grises GLCM (Grey Level Co-occurrence Matrix), basadas en las estadísticas de segundo orden. Es un histograma de niveles de grises en dos dimensiones para un par de pixeles (referencia y vecino). Esta matriz aproxima la probabilidad de distribución conjunta de un par de pixeles. La relación espacial (distancia d , ángulo $theta$) entre el pixel de referencia y su vecino: puede ser en cualquiera de las 8 direcciones (N, S, E, O y las 4 diagonales), pero sólo se toman cuatro, ya que la N es opuesta a la S y se puede usar la matriz simétrica para medirla (Presutti, 2004) (esto también se expresa respectivamente como 0° , 45° , 90° y 135°). El valor de la distancia se modifica en función del tamaño de la imagen N y el tipo de textura que se pretende analizar.

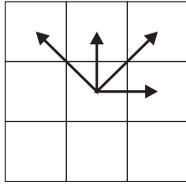


Figura 3. GLCM con $d = 1$, $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$.

Entre las propiedades más importantes de la matriz de co-ocurrencia se encuentra que es simétrica sobre su diagonal y cuadrada debido a la igualdad del rango de valores de los píxeles con respecto a los píxeles vecinos.

Las variaciones locales de la GLCM proporciona el valor de contraste opuesto al valor de homogeneidad: a mayor contraste menor homogeneidad. A su vez, se encuentra que la homogeneidad es alta si los valores se concentran sobre la diagonal de la matriz.

Si la GLCM posee valores constantes entre vecinos decrece su energía, y si estos valores se acercan a 0 o 1 baja también la entropía. Píxeles cercanos están más correlacionados que píxeles lejanos. Aumenta la correlación si la probabilidad de ocurrencia de los valores dentro de la matriz es alta.

3.3. Análisis de las GLCM

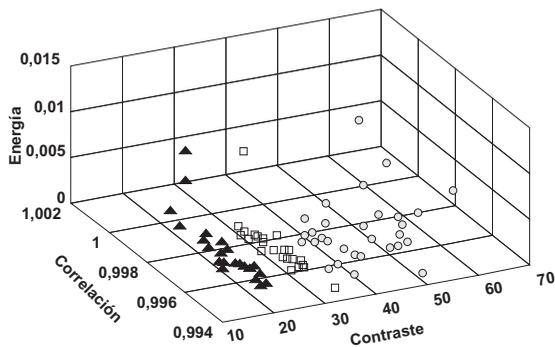


Figura 4. Medidas de: Contraste-Correlación-Energía.

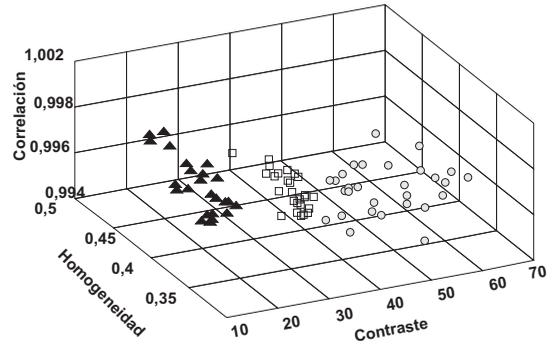


Figura 5. Medidas de: Contraste - Correlación - Homogeneidad.

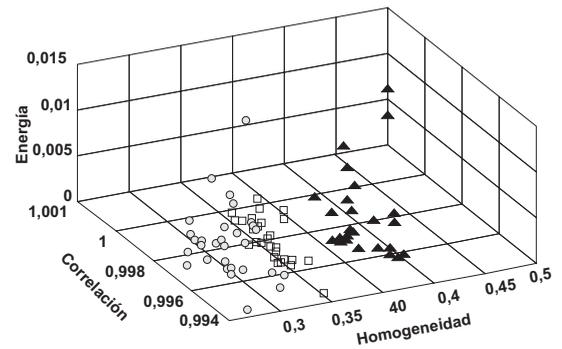


Figura 6. Medidas de: Energía - Correlación - Homogeneidad.

Por medio de 90 muestras distribuidas en 30 por cada textura y los descriptores: contraste, correlación, energía y homogeneidad obtenemos las figuras 4, 5, 6 y 7, donde el triángulo representa los valores obtenidos de la GLCM del Icopor, el cuadrado el de la madera y el rombo los valores de la matriz para el ladrillo.

De las figuras 4 y 5 se observa que los valores de contraste determinan la separabilidad de los tres tipos de texturas, y en la figura 6 lo determina el descriptor homogeneidad; anexando que esta última no es muy concluyente debido a algunas muestras que se solapan entre la madera y el ladrillo.

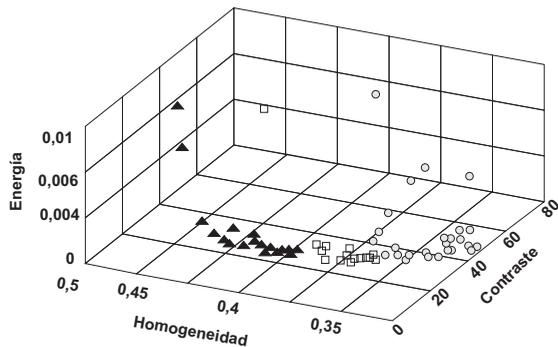


Figura 7. Medidas de: Energía - Correlación - Homogeneidad.

De la figura 7, aunque la energía no es determinante como descriptor de separabilidad, observamos que tanto la homogeneidad y el contraste si lo son, y a diferencia de las figuras 4 y 6 donde prácticamente tenemos un solo parámetro de separabilidad, los descriptores (energía - correlación), homogeneidad y contraste serían los más convenientes dentro del problema de clasificación de las texturas.

2.3. Algoritmo de k-means

K-means es un método de agrupamiento que tiene como objetivo la partición de un conjunto n de observaciones en k grupos, en el que cada observación pertenece al grupo más cercano a la media. El objetivo del agrupamiento es *particionar* un grupo de objetos, los cuales tienen asociados los vectores multidimensionales de atributos en grupos homogéneos tales que los patrones en cada grupo sean similares (Duda y Hart, 1973). De acuerdo a la literatura especializada (Kanungo y Netanyahu, 2002) se pueden identificar tres pasos en el algoritmo:

1. Inicialización: se define un conjunto de objetos a *particionar*, el número de grupos y un centroide por cada grupo. Algunas implementaciones del algoritmo estándar determinan los centroides iniciales de forma aleatoria; mientras que otros procesan los datos y determinan los centroides mediante cálculos.
2. Cálculo de centroides: a partir de una medida de

distancia, que suele ser la distancia euclídea; para cada grupo generado de n elementos se calcula el valor de los centroides con base en la ecuación (6).

$$c = \frac{1}{n} (\sum x_i, \sum y_i, \sum z_i) \quad (6)$$

3. Clasificación: se determina el centroide más cercano para cada punto, y el objeto es incorporado al grupo relacionado con ese centroide. Se repiten las etapas 2 y 3 hasta que no se hagan más reasignaciones. Aunque el algoritmo termina siempre, no se garantiza obtener una solución óptima. En efecto, el algoritmo es muy sensible a la elección aleatoria de los K centros iniciales (García, 2008). Esta es la razón por la que se utiliza el algoritmo numerosas veces sobre un mismo conjunto de datos para intentar minimizar este efecto, sabiendo que centros iniciales lo más espaciados posibles dan mejores resultados.

El solapamiento de datos impide que el algoritmo de aprendizaje inductivo no supervisado k-means, sea capaz de generar un proceso de clasificación. Por esta razón, la tríada (Ene, Cor, Hom) de la figura 6, se descarta para la aplicabilidad del algoritmo con el porcentaje más bajo de efectividad (vease la tabla 2).

Tabla 2. Efectividad en la clasificación

Descriptores	Efectividad
Con-Cor-Ene	90%
Con-Hom-Cor	93%
Hom-Cor-Ene	40%
Con-Hom-Ene	93%

Fuente: propia

Los porcentajes de efectividad no aumentan más del 93%, debido en su mayoría a la GLCM de la textura del ladrillo, la cual se presenta en rangos de contraste no uniformes, y su homogeneidad también es variable donde la imagen toma la textura en lugares rugosos y otras donde la toma en lugares lisos.

La iluminación juega un rol importante sobre la energía y el contraste; para ello se instaló un sistema

de luz LED diagonal a la superficie a tratar, con ello se normalizó más las matrices de co-ocurrencia.

2.4. Funcionamiento del Hardware

Dentro del hardware utilizado se identifican las partes: tarjeta Raspberry Pi modelo B, la Raspicam, el módulo wi-fi y la tarjeta de potencia que a su vez incorpora el microcontrolador PIC16F628A.

El proceso es: la cámara (Raspicam) conectada a la tarjeta Raspberry toma video en tiempo real y es retransmitido por el módulo wi-fi hacia el software; que a su vez procesa y clasifica las diferentes texturas, y de allí se envía la información necesaria para que la clasificación se haga efectiva de forma física.

2.4.1. Tarjeta Raspberry PI

Raspberry Pi es un ordenador de placa reducida (SBC) de bajo costo, desarrollado en el Reino Unido por la Fundación Raspberry Pi, con el objetivo de estimular la enseñanza de ciencias de la computación en la academia (Fundación Raspberry, 2010). El modelo A tiene un puerto USB, carece de controlador

Ethernet y cuesta menos que el modelo B, el cual tiene dos puertos USB, controlador Ethernet 10/100, 512MB de memoria SDRAM y un procesador ARM de 700MHz. La tarjeta incorpora 17 puertos GPIO (*General Purpose Input Output*) para la conexión con otros dispositivos.

2.4.2. Tarjeta de Potencia

Debido a la baja potencia entregada por los puertos GPIO es necesario realizar una amplificación para poder mover el motor de la banda transportadora.

Un servomotor puede ser llevado a posiciones angulares específicas al enviar una señal codificada. Con tal de que una señal codificada exista en la línea de entrada, el servo mantendrá la posición angular del engranaje. Cuando la señal codificada cambia, la posición angular de los piñones cambia (Riazollah, 2010). El servomotor se posiciona en 135 grados cuando se clasifica la textura del ladrillo, 90° para la madera y 45° para el *icopor*; en la figura 10 se observan las guías para la clasificación de los extremos.

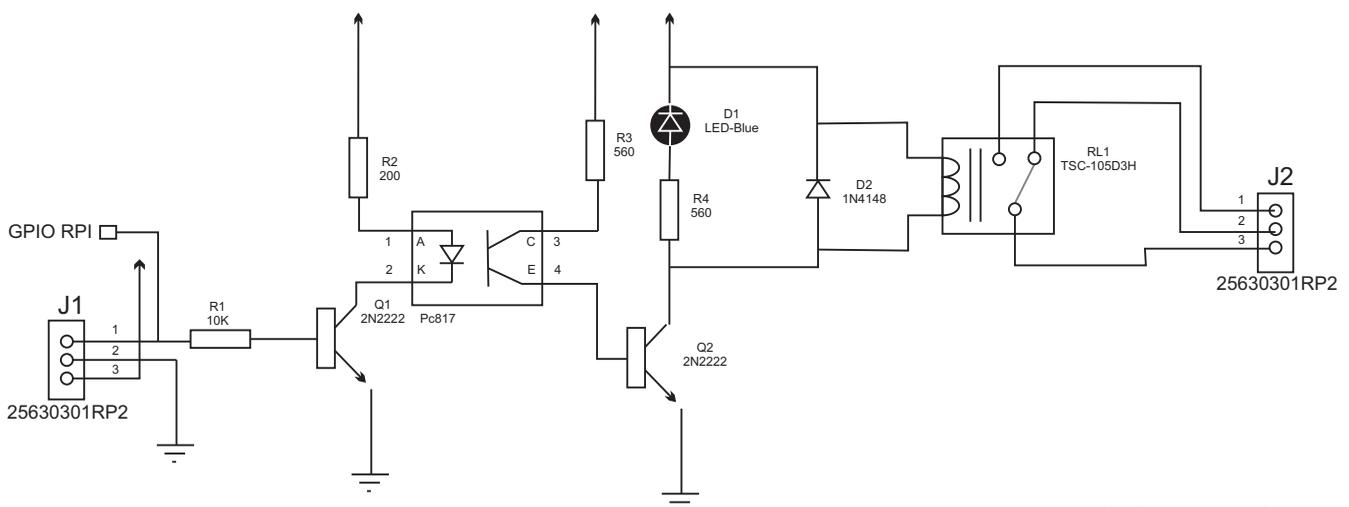


Figura 9. Diseño módulo de Potencia.

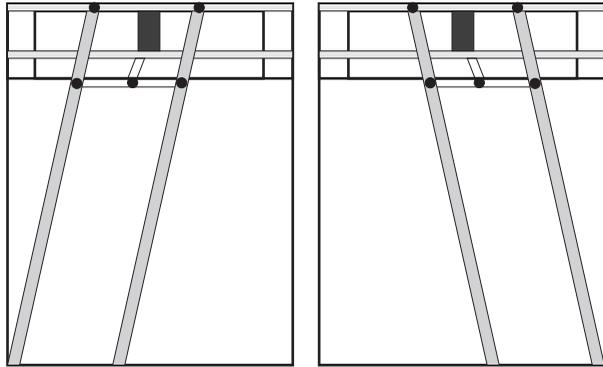


Figura 10. Distribución en grados del servomotor.

El microcontrolador PIC 16F628A que opera con 8 bits y un juego reducido de 35 instrucciones (Ortiz, 2015) recibe la orden de clasificación y envía la señal de control hacia el servomotor para posicionar correctamente las guías respectivas de clasificación.

2.4.3. RaspiCam

El módulo de la cámara Raspberry Pi (Raspicam) se puede utilizar para tomar video de alta definición, así como fotografías. El módulo tiene una cámara de foco fijo de cinco megapíxeles que soporta 1080p30, 720p60 y video VGA, así como imágenes fijas de captura. Se une a través de un cable de cinta de 15 cm al puerto CSI en la Raspberry Pi.

2.5. Interfaz de Usuario

La interfaz de usuario como componente de control e indicación de que el usuario posee sobre todo el sistema, consta de tres paneles: el primer panel inicia la banda transportadora y ella envía la imagen inalámbrica respectiva de la textura para que la interfaz la muestre e indique las medidas *texturales* respectivas dentro del segundo panel. Los valores de las medidas se van agrupando dentro de la imagen principal, la cual también muestra los respectivos centroides. La clasificación y su conteo respectivo se hace dentro del tercer panel, denominado de cuantización: allí se va realizando un conteo ascendente sobre las texturas clasificadas y el total de elementos que se identificaron como texturas.

Una vez se termina la sesión o se reinicia la interfaz todos los valores de la cuantización respectiva vuelven a cero para iniciar nuevos conteos, al pausar se detiene la banda transportadora y los conteos se congelan; se reinicia con el mismo botón.

3. CONCLUSIONES

En este artículo se ha presentado una técnica de aprendizaje inductivo no supervisado denominado k-means, usado en este caso como discriminador de texturas sobre la matriz de co-ocurrencia.

La implementación del algoritmo requiere encontrar los centroides adecuados que minimicen la distancia euclídea entre una tríada de la matriz GLCM y los centroides.

Al escoger los discriminatorios sobre los estadísticos de segundo orden se encuentra que la energía, el contraste, la homogeneidad y la correlación son los parámetros que mejores diferencias presentan sobre las texturas, por esta razón se analizan sus diferentes combinaciones y con cierta similitud sobre la eficiencia en la clasificación entre la homogeneidad, el contraste y la energía con respecto a la homogeneidad, el contraste y la correlación, se escoge el primer grupo para el desarrollo. No obstante, el buen uso de la iluminación determina que el k-means y los descriptores *texturales*, sobre la imagen enviada inalámbricamente al software Matlab, clasifique correctamente la textura. El evitar solapamientos continuos entre los descriptores hace que el algoritmo posea más éxito, por ende, al aumentar las texturas se tendrían pérdidas en la eficiencia de aplicación.

Por último, la tecnología Raspberry Pi y periféricos se acopla muy bien a la comunicación con Matlab 2014B, la cual consta de paquetes de soporte para el uso de los módulos wi-fi, Raspicam y microcontroladores entre otros.

REFERENCIAS

GIL RODRÍGUEZ, J. (2008) *Estado actual de representación*

y análisis de texturas en imágenes. RNPS 2142. Cenatav. Series Azul.

- UNIVERSIDAD REY JUAN CARLOS (2015). *Tema 4: Características de los patrones percibidos por un SVA*. Consulta 17-03-2015:
<http://www.escet.urjc.es/~visiona/tema4.pdf>
- HARALICK, R. M., SHANMUGAN, K. y DINSTEN, I. (1973). *Textural features for image classification*. IEEE Transaction on System, Man and Cybernetics, Vol SMC- 3 N° 6, pp 610-621.
- JENSEN, J. R. (1996). *Introductory Digital Image Processing* (Second Edition), Ed. Prentice Hall,
5. Pressuti, M. (2004). *La matriz de co-ocurrencia en la clasificación multispectral para la enseñanza de medidas texturales en curso de grado universitario*. 4ta Jornada de Educación en senso remoto. Brasil.
- FERNÁNDEZ, J. et al. (2010). *Estudio comparativo de técnicas espaciales para la identificación de defectos textiles*. ITECKNE. Volúmen 7. Pág. 75-82.
- CAICEDO, J. et al. (2006). *Prototipo de Sistema para almacenamiento y recuperación por contenido de imágenes médicas de Histopatología*. UNC.
- SUTTON, R. y HALL, E. (1972). *Texture measures for automatic classification of pulmonary disease*. IEEE Trans. On-Computing, 21(7):667-676.
- PÉREZ, J. A. (2008). *Apuntes de Fotogrametría II*. Universidad de Extremadura España. Consulta en web (18-03-2015)
- PASCUAL, D. (2015). *Algoritmos de Agrupamiento*. Universidad de Oriente Santiago de Cuba. Consulta en web (18-03-2015):
http://marmota.dlsi.uji.es/WebBIB/papers/2007/1_Pascua1-MIA-2007.pdf
- STORK, D. G., DUDA, R. O. y HART, P. E. (1973). *Pattern classification and scene analysis*. John Wiley and sons, New York.
- KANUNGO, T. et al. (2002) *An efficient K-means clustering algorithm: Analysis and implementation*. IEEE. Journal Pattern Analysis and Machine Intelligence; Volume 24, Issue 7. Pages 881-892.
- GARCÍA, C. y GÓMEZ, I. (2008). *Algoritmos de Aprendizaje: KNN & K-means*. Consulta en web 26-05-2015:
<http://www.it.uc3m.es/jvillena/irc/practicas/08-09/06.pdf>
- FUNDACIÓN RASPBERRY. Consultado el 26-05-2015, en:
<http://www.raspberrypi.org>
- RIAZOLLAH, F. (2010). *Servo motors and Industrial Control Theory*. Springer.
- ORTIZ MARTÍNEZ, J. (2015) *Microcontroladores Pic*. DataSheet microcontrolador 16F628. Granada España. Última consulta: 25-05-2015:
<http://www.microcontroladorespic.com>