Universidad Central "Marta Abreu" de Las Villas

Facultad de Ingeniería Eléctrica



TRABAJO DE DIPLOMA

Mezcla de regiones en imágenes sobresegmentadas usando rasgos de textura

Autor: Reinier Peñarroche Díaz

Tutores: MSc. Maikel Orozco Monteagudo

MSc. Denis Hernández Pacheco

Santa Clara

2013

"Año 55 de la Revolución"

Universidad Central "Marta Abreu" de Las Villas

Facultad de Ingeniería Eléctrica



TRABAJO DE DIPLOMA

Mezcla de regiones en imágenes sobresegmentadas

usando rasgos de textura

Autor: Reinier Peñarroche Díaz

Tutores: MSc. Maikel Orozco Monteagudo

Profesor Auxiliar. CEETI. Facultad de Ingeniería Eléctrica. UCLV. E-mail: morozco@uclv.edu.cu

MSc. Denis Hernández Pacheco

ETECSA E-mail: <u>denis.hernadez@etecsa.cu</u>

Santa Clara

2013

"Año 55 de la Revolución"



Hago constar que el presente trabajo de diploma fue realizado en la Universidad Central "Marta Abreu" de Las Villas como parte de la culminación de estudios de la especialidad de Ingeniería en Automática, autorizando a que el mismo sea utilizado por la Institución, para los fines que estime conveniente, tanto de forma parcial como total y que además no podrá ser presentado en eventos, ni publicados sin autorización de la Universidad.

Firma del Autor

Los abajo firmantes certificamos que el presente trabajo ha sido realizado según acuerdo de la dirección de nuestro centro y el mismo cumple con los requisitos que debe tener un trabajo de esta envergadura referido a la temática señalada.

Firma del Tutor

Firma del Jefe de Departamento donde se defiende el trabajo

Firma del Responsable de Información Científico-Técnica

PENSAMIENTO

La primera muestra de cultura de un hombre es la educación.

José Martí

DEDICATORIA

Quiero dedicar este trabajo a las dos personas más importantes que tengo en mi vida, sin ellos no hubiera sido posible hacer realidad este sueño:

a mis abuelos.

AGRADECIMIENTOS

Quiero agradecer la realización de este trabajo a mis dos tutores, MSc. Maykel Orozco Monteagudo y MSc. Denis Hernández Pacheco por su ayuda y apoyo incondicional y a toda mi familia que siempre estuvo presente en las buenas y malas.

No puedo dejar de darle las gracias a todos mis compañeros de aula, no menciono nombres porque sería injusto, todos de una forma u otra me ayudaron en su momento. A los que empezaron conmigo desde un principio en esta universidad, Heriberto, Jelson, Saimy, Morín, Alfonso, José A, Treto, Yuri, Alexis, Roberto y en general a todo ese grupo que terminó primero que yo. A Luzma por su apoyo a pesar de la distancia, a Rosy por aguantarme todo el estrés de la recta final, a todos mis amigos de Sancti Spiritus y de la universidad que estuvieron a mi lado en el momento que más lo necesité.

TAREA TÉCNICA

- Aprender los fundamentos de:
 - ✓ Segmentación de imágenes.
 - ✓ Resolución del problema de la sobresegmentación usando mecanismos de mezcla.
 - ✓ Análisis de textura.
- Realizar un estudio específico sobre las siguientes técnicas de segmentación de imágenes:
 - Marcas de agua (*Watershed*).
- Realizar una revisión bibliográfica relacionada con la segmentación de núcleos en imágenes de la prueba de Papanicolaou.
 - Aprender a usar la *toolbox* de Procesamiento de Imágenes y Estadística de *Matlab*.
- Segmentar imágenes de la prueba de Papanicolaou usando la transformada watershed.
 - Realizar la mezcla de regiones usando combinaciones de rasgos de textura.
 - Medir la calidad de las regiones que representan los núcleos detectados.
- Comparar los resultados obtenidos con los reportados en la literatura.

Firma del Autor

Firma del Tutor

RESUMEN

En el presente trabajo se realiza un estudio sobre el análisis de textura y su uso en la resolución del problema de la sobresegmentación en imágenes biomédicas. Las imágenes sobresegmentadas se obtuvieron usando la transformada *watershed* aplicadas sobre su gradiente. Para realizar la mezcla se usó el algoritmo de la caída de agua (*waterfall*) utilizando rasgos de textura (específicamente los conocidos como medidas de Haralick) dentro de las medidas de similitud entre segmentos. En estas funciones de similitud entre segmentos se usaron puramente rasgos de textura o combinaciones de estos con otros rasgos de color o forma.

Los resultados obtenidos usando rasgos de textura no fueron significativamente superiores a los resultados obtenidos sin usar rasgos de textura. La principal conclusión de este estudio es precisamente esa: la utilización de estos rasgos de textura no mejora significativamente los resultados de la mezcla.

TABLA DE CONTENIDOS

PENSAMIENTO	i
DEDICATORIA	ii
AGRADECIMIENTOS	iii
TAREA TÉCNICA	iv
RESUMEN	v
TABLA DE CONTENIDOS	vi
INTRODUCCIÓN	1
CAPÍTULO 1. EL ANÁLISIS DE TEXTURA	3
1.1 La textura dentro del procesamiento digital de imágenes	3
1.2 Métodos de detección de la textura visual	5
1.3 Los rasgos de textura basados en la matriz de co-ocurrencia de niveles de gris.	7
1.4 Rasgos de textura	9
CAPÍTULO 2. SEGMENTACIÓN DE IMÁGENES Y MEZCLA DE REGIO	ONES
USANDO RASGOS DE TEXTURA	13
2.1 La prueba de Papanicolaou	13
2.2 La base de imágenes Herlev de la prueba de Papanicolaou	15
2.3 Fundamentos teóricos sobre algoritmos de segmentación de imágenes	17
2.4 Transformada Watershed	19
2.4.1 Mezcla de regiones pequeñas.	20

2.5 El algoritmo de la "caída de agua" (<i>waterfall</i>) para la mezcla de regiones	20
RESULTADOS Y DISCUSIÓN	23
3.1 Medida de <i>Vinet</i>	23
3.2 Selección de los rasgos de textura que mejor describen las regiones en las	imágenes
de la prueba de Papanicolau	24
3.3 Medidas de similitud	25
3.4 Resultados	27
CONCLUSIONES	32
RECOMENDACIONES	
REFERENCIAS BIBLIOGRÁFICAS	34
ANEXO 1	37

INTRODUCCIÓN

El análisis de textura es un área importante del análisis e interpretación de imágenes a la que desde la década de 1980 se está prestando especial interés, debido a las crecientes investigaciones en los campos de la visión artificial y del procesamiento de imágenes [1].

La textura es una propiedad que está presente en la superficie de los objetos reales y contiene información importante acerca de su estructura. Aunque es muy fácil para el observador humano reconocerla y describirla en términos empíricos, es extremadamente difícil definirla de forma precisa y realizar su análisis mediante cálculos [1].

La textura cuenta con importantes aplicaciones en el análisis de imágenes médicas y satelitales, la codificación de imágenes, la inspección de superficies, la identificación de objetos, entre otros.

Desde la década del 1960, el análisis de textura ha sido un área de intensa investigación. No obstante, el progreso ha sido lento con la introducción de solo unas pocas mejoras notables. Los métodos desarrollados ocasionalmente han sido utilizados en aplicaciones reales. El análisis de textura basado en imágenes del mundo real ha probado ser extremadamente difícil, quizás la mayor dificultad se debe a la falta de homogeneidad de las texturas, la variación de la iluminación y la variabilidad en la forma de la superficie [1].

Por otro lado, la segmentación de imágenes consiste en la división coherente de una imagen en regiones que determinen los objetos reales. Este ha sido uno de los campos más estudiados dentro del procesamiento de imágenes aunque siempre hay margen para mejoras al respecto. Dentro de los métodos más usados en segmentación de imágenes se encuentran los métodos morfológicos, específicamente la transformada *watershed* [2]. Su principal desventaja, la sobresegmentación, ha sido abordado mediante mecanismos de mezcla que han arrojado excelentes resultados [3, 4].

El uso de algoritmos de mezcla que hagan uso de rasgos obtenidos mediante un análisis de textura es la principal motivación de este trabajo. Dentro de las imágenes biomédicas, específicamente, las imágenes de microscopía celular abundan las regiones cuidadosamente texturizadas (p. e. la cromatina presente en los núcleos celulares, los orgánulos presentes en el citoplasma) [5-7].

El presente trabajo consta de un objetivo principal y varios objetivos específicos que se enuncian a continuación:

Objetivos del trabajo

Segmentar imágenes biomédicas utilizando la transformada *watershed* y la mezcla de regiones a partir de rasgos de textura.

Objetivos específicos

- Segmentar imágenes de la prueba de Papanicolaou usando la transformada watershed.
- Crear funciones de similitud que contengan rasgos de textura para mezclar correctamente las distintas regiones de las imágenes de la prueba de Papanicolaou.
- Comparar los resultados obtenidos con otros reportados en la literatura.

El informe de este trabajo consta de tres capítulos, conclusiones, recomendaciones, bibliografía y anexos. En el capítulo 1 se tratan los fundamentos teóricos del análisis de textura haciendo hincapié en los rasgos de textura basados en la matriz de coocurrencia de niveles de gris. En el segundo capítulo se trata la segmentación morfológica de imágenes basada en la transformada *watershed* y el algoritmo de *waterfall* para la mezcla de regiones. En el tercer capítulo se realiza un análisis de los resultados obtenidos a partir de las funciones de similitud de regiones basadas en rasgos de textura. Por último, la sección de las conclusiones enuncian las conclusiones obtenidos en este trabajo.

CAPÍTULO 1. EL ANÁLISIS DE TEXTURA

En este capítulo se hace una revisión del estado del arte de los principales métodos utilizados para el análisis de textura.

1.1 La textura dentro del procesamiento digital de imágenes

El análisis de textura se divide en cuatro áreas principales:

- la clasificación de texturas,
- la segmentación de imágenes de texturas,
- la síntesis de texturas,
- la modelación de texturas.

Características de la textura visual

En términos generales la textura puede definirse como una característica visual o táctil de la superficie de un objeto. En las imágenes digitales, la textura visual se representa como variaciones de los valores de las intensidades de los píxeles que forman ciertos patrones repetitivos (Fig. 1). La causa puede deberse a las propiedades físicas de la superficie de los objetos, o a los cambios en la absorción y reflexión de la iluminación. Puede decirse que todos los objetos se caracterizan por tener textura si se observan a la distancia apropiada y con diferentes grados de atención, y las imágenes pueden considerarse como mosaicos de texturas separadas por fronteras, por lo que la clasificación de texturas combinada con la segmentación es una herramienta muy poderosa en el análisis de imágenes [8].





Fig. 1 Regiones con textura. a) Tejido de tela que da un efecto de zigzag. (b) Cuero de ternero corrugado. (c) Agua. (d) Arreglo de hoyos hexagonales. (e) Tejido de tela que da un efecto de zigzag. (f) Corteza de árbol. (g) Piel de cerdo. (h) Fibra de la palma rafia.

Las diferencias en los valores de intensidad de los píxeles de la imagen proporcionan un medio práctico para analizar las propiedades de textura de los objetos. Desafortunadamente, no se ha podido definir la textura digital en términos matemáticos [9]. Cross y Jain, en 1983 [10], analizando la textura mediante los modelos de Markov, planteaban que la textura visual, podía considerarse como estocástica y posiblemente periódica. Pero 13 años después aún no estaba muy clara la definición de textura [11]. Desde el punto de vista matemático, no contar con un modelo que defina la textura hace que análisis de textura sea un problema debido a que como no puede comprobarse la validez de los métodos de análisis, su evaluación debe realizarse de manera empírica. Sin embargo, las medidas de textura se han utilizado satisfactoriamente en muchas aplicaciones de la visión artificial [1].

Muchos investigadores han categorizado la textura de acuerdo a su apariencia. La forma más simple consiste en dividir la textura en dos categorías: estocástica y determinista. Otra forma propuesta por Rao y Lohse [12], basada en las características más importantes del sistema visual humano, categoriza la textura en tres dimensiones ortogonales: repetitiva vs no repetitiva, no direccional con alto contraste vs direccional con bajo contraste, y texturas simples granulares vs texturas complejas de granos finos.

Caracterizar una imagen en diferentes clases de textura a menudo es una tarea trivial para el sistema visual humano [13], pero es uno de los retos más importantes en los campos de la visión artificial y del procesamiento de imágenes. Aun cuando el color es un atributo importante para la interpretación de imágenes, existen situaciones donde las mediciones del color no son suficientes o aplicables. Las medidas de textura tienden a funcionar mejor en condiciones reales donde hay variabilidad en la iluminación.

El problema del análisis de textura normalmente se divide en dos etapas: 1) extracción de rasgos, y 2) clasificación. Para diseñar un algoritmo efectivo para la segmentación de texturas, es esencial encontrar un conjunto de rasgos de textura con un buen poder discriminante [14]. Existen varias técnicas de extracción de textura, aunque no se ha podido validar experimentalmente la superioridad de unas sobre otras, entre las más utilizadas pueden citarse los métodos de la aproximación estadística, entre estos, los rasgos de textura basados en la matriz de coocurrencia de niveles de gris propuestos por Haralick en la década de 1970 [9].

1.2 Métodos de detección de la textura visual

Los métodos de detección de textura tradicionalmente se han dividido en dos categorías.

La primera, denominada aproximación estadística o estocástica, trata la textura como un fenómeno estadístico. La formación de textura se describe a partir de las propiedades estadísticas de las intensidades y posiciones de los píxeles. La diferencia de histogramas y la matriz de ocurrencia de niveles de gris, investigados por Haralick, Weszka [15], y Unser [16], son ejemplos simples de este tipo de medidas de textura. La aproximación estadística de textura describe mejor las texturas estocásticas.

La segunda categoría, denominada aproximación estructural, introduce el concepto de primitivas de textura, a menudo llamados *textones* o *texels*. Estos métodos para describir la textura, requieren de un vocabulario de *texels* y de una descripción de sus interrelaciones.

Aproximación	Método		
	1. Propiedades del histograma		
	2. Matriz de ocurrencia de niveles de gris		
	3. Patrón binario local		
Estadística	4. Autocorrelación		
	5. Operaciones morfológicas		
	6. Detección de bordes		
	7. Basado en registro		
Estructural	1. Mediciones primitivas		
	2. Representación esquelética		
	1. Filtrado en el dominio espacial		
Procesamiento de señales	2. Análisis en el dominio de la frecuencia		
	3. Combinación de 1 y 2		
	1. Modelos fractales		
Basado en modelos	2. Modelos aleatorios		

Tabla 1.1. Algunos métodos de detección de textura.

El objetivo es representar estructuras complejas con primitivas simples [17]. Se ha demostrado que los modelos de textura estructurales representan mejor las texturas deterministas o estructuralmente bien definidas. Desde el trabajo pionero de Julesz [17], y Beck [18], los modelos basados en primitivas, se han utilizado bastante para realizar estudios sobre la percepción humana de la textura. Sin embargo, el problema con la correlación entre los dos modelos de textura, ha sido reconocido recientemente por

Sánchez Yañez [19], la textura contiene tanto características estadísticas como regulares y en la práctica pueden encontrarse texturas periódicas y aleatorias a la vez, por lo que se hace extremadamente difícil clasificar la textura basado en un único método.

Otra forma de clasificación de los métodos de textura fue propuesta por Chellappa y Manjunath [20]. De acuerdo a la misma, los métodos modernos, tratan, o de entender el proceso de formación de textura, o se basan en la teoría de la percepción humana de la textura. Se han realizado una categorización más específica en la que los métodos de textura se dividen en aproximaciones estadísticas, estructurales, de procesamiento de señales y basadas en modelos. En la tabla 1.1 se muestra una lista de algunos métodos de detección de textura clasificados según estas categorías.

El proceso de formación de textura puede describirse usando los procesos de Markov o los modelos autorregresivos. Hasta hace poco, los modelos aleatorios Gaussianos de Markov, estudiados por Chellappa [21], se utilizaron como modelos generales de textura. Desde el comienzo de la década de los años 1980, los modelos basados en el procesamiento de señales ganaron mucho interés. Por otra parte, el primer trabajo que asoció el modelo visual humano al análisis de textura fue el presentado por Faugeras [22]. En la actualidad, el filtrado de Gabor, usado en un principio para el análisis de imágenes por Granlund [23], se considera el método de análisis de textura más comúnmente utilizado por la comunidad científica.

Este método propuesto por Manjunath y Ma [24], ha mostrado un buen desempeño en un número considerable de estudios comparativos. La fortaleza del método puede atribuirse a la incorporación del análisis de las frecuencias espaciales y la información de bordes locales. Aunque teóricamente elegante, tiende a ser computacionalmente muy demandante, especialmente al aumentar el tamaño de la máscara, y es muy sensible a las variaciones de la iluminación [1].

1.3 Los rasgos de textura basados en la matriz de co-ocurrencia de niveles de gris.

Haralick [9], propuso el uso de las medidas de textura basadas en la matriz de ocurrencia de niveles de gris, también llamada matriz de dependencia espacial de tonos de gris (*Gray Level Co-occurrence Matrix*, GLCM, o *Gray Tone Spatial Dependency Matrix*, GTSDM,

por sus siglas en inglés), para el análisis de textura. Esta representación se ha convertido en uno de los descriptores de textura más conocidos y utilizados.

La ocurrencia espacial de niveles de gris proporciona un estimado de las propiedades de la imagen que está relacionado con los estadísticos de segundo orden. Los estadísticos de primer orden miden la probabilidad de observar un valor de gris en una región de la imagen elegida de forma aleatoria y pueden calcularse a partir del histograma de niveles de gris de la imagen, porque dependen solamente de los valores de los píxeles individuales y no de la interacción u ocurrencia de los valores de los píxeles vecinos. Entre los estadísticos de primer orden pueden mencionarse los agrupados como medidas de la tendencia central y como medidas de dispersión.

Las medidas de segundo orden o más consideran la relación que existe entre dos o más píxeles, usualmente vecinos, de la imagen original. Generalmente las medidas mayores de orden 2 no se implementan, debido a que consumen mucho tiempo de cálculo y a su dificultad de interpretación.

Definamos dos GLCM, Pd_5 y Pd_E , para un desplazamiento dx, por filas, y dy, por columnas, para las direcciones sur y este, respectivamente:

$$Pd(i,j) = \sum_{c=1}^{C} \sum_{r=1}^{R} |(I(r,c), I(r+dx,c)) = (i,j)|$$
(1.1)

y para la dirección este como:

$$Pd(i,j) = \sum_{c=1}^{C} \sum_{r=1}^{R} |(I(r,c), I(r,c+dy)) = (i,j)|$$
(1.2)

En ambas ecuaciones R, C, son el tamaño en píxeles de la imagen I por filas y por columnas, el conjunto (i,j), la combinación de niveles de gris buscada. Las medidas de textura requieren:

1) que la GLCM sea una matriz simétrica, esto se hace sumando a la GLCM su matriz

transpuesta y,

2) que en lugar de estar formada por números representando la ocurrencia de niveles de gris, esté en función de su probabilidad de ocurrencia.

La primera condición se logra sumando a la GLCM su matriz transpuesta, para la dirección sur y este es, respectivamente, como sigue:

$$\widetilde{Pd}_{S} = Pd_{S} + Pd_{S}^{T} \tag{1.3}$$

$$\widetilde{Pd_E} = Pd_E + Pd_E^T \tag{1.4}$$

La segunda condición se logra mediante el proceso denominado normalización de la GLCM se obtiene dividiendo cada valor de coocurrencia de un nivel de gris por la suma de todos los valores de coocurrencias de niveles de gris [25]. Para dirección sur se define como:

$$P = \frac{\widetilde{Pd_S}}{\sum_{c=1}^{C} \sum_{r=1}^{R} \widetilde{Pd_S}}$$
(1.5)

Para la dirección este sería:

$$P = \frac{\widetilde{Pd}_E}{\sum_{c=1}^C \sum_{r=1}^R \widetilde{Pd}_E}$$
(1.6)

1.4 Rasgos de textura

Haralick et al. propusieron 13 rasgos basados en la GLCM que describen alguna de las características de la textura [9].

Notación:

$$p_x(i) = \sum_{j=1}^{Ng} p(i,j).$$

Ng: Cantidad de niveles de gris.

 $\Sigma_i \equiv \Sigma_{i=1}^{Ng}$ $\Sigma_j \equiv \Sigma_{j=1}^{Ng}$

$$p_j(j) = \sum_{j=1}^{Ng} p(i,j)$$

$$p_{x+y}(k) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i,j), \quad i+j=k, \quad k=2,3,\dots,2Ng$$

$$p_{x+y}(k) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i,j), \quad |i-j| = k, \quad k = 0,1, \dots, Ng-1$$

1. Segundo Momento Angular (ASM):

$$H_1 = \sum_i \sum_j \{p(i,j)\}^2$$
(1.7)

2. Contraste:

$$H_2 = \sum_{n=0}^{Ng-1} \cdot n^2 \cdot \left(\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i,j), |i-j| = n \right)$$
(1.8)

3. Correlación:

$$H_{3} = \frac{\sum_{i} \sum_{j} (i \cdot j) \cdot p(i, j) - \mu_{\chi} \cdot \mu_{y}}{\sigma_{\chi} \cdot \sigma_{y}}$$
(1.9)

donde σ_x , σ_y , μ_x y μ_y son las medias y las desviaciones estándar de p_x y p_y .

4. Suma de cuadrados (varianza):

$$H_4 = \sum_{i} \sum_{j} \cdot (i - \mu)^2 \cdot p(i, j)$$
(1.10)

5. Diferencia de momento inverso:

$$H_{5} = \sum_{i} \sum_{j} \frac{1}{1 + (i - j)^{2}} \cdot p(i, j)$$
(1.11)

6. Suma de promedio:

$$H_{6} = \sum_{i=2}^{2Ng} i \cdot p_{x+y} \cdot (i)$$
(1.12)

7. Suma de la varianza:

$$H_7 = \sum_{i=2}^{2Ng} (i - H(8))^2 \cdot p_{x+y} \cdot (i)$$
(1.13)

8. Suma de entropía:

$$H_8 = -\sum_{i=2}^{2Ng} p_{x+y} \cdot (i) \cdot \log(p(i,j))$$
(1.14)

9. Entropía:

$$H_{9} = -\sum_{i=1}^{N_{g}} \sum_{j=1}^{N_{g}} p(i,j) \cdot \log(p(i,j))$$
(1.15)

10. Diferencia de varianza:

$$H_{10} = H_4 de \, p_{x-y} \tag{1.16}$$

11. Diferencia de entropía:

$$H_{11} = -\sum_{i=0}^{N_g - 1} p_{x-y} \cdot (i) \cdot \log(p_{x-y}(i))$$
(1.17)

12. Información del coeficiente de correlación:

$$H_{12} = \frac{-\sum_{i} \sum_{j} p(i,j) \cdot \log(p(i,j)) - (-\sum_{i} \sum_{j} p(i,j) \cdot \log(p_{x} \cdot (i) \cdot p_{y} \cdot (j)))}{\max(H_{9} de \ p_{x} \cdot H_{9} de \ p_{y} \cdot)}$$
(1.18)

13. Información del coeficiente de correlación:

$$H_{13} = (1 - \exp(-2\left(-\sum_{i}\sum_{j}p(i,j) \cdot \log\left(p_{x} \cdot (i) \cdot p_{y} \cdot (j)\right)\right)) - \left(-\sum_{i}\sum_{j}p(i,j) \cdot \log\left(p(i,j)\right)\right)^{2}$$

$$(1.19)$$

CAPÍTULO 2. SEGMENTACIÓN DE IMÁGENES Y MEZCLA DE REGIONES USANDO RASGOS DE TEXTURA

En el presente capítulo se describirán los materiales utilizados en la experimentación, así como los métodos de segmentación y mezcla que fueron probados.



2.1 La prueba de Papanicolaou

Fig. 2.1. Útero y localización de las células columnares y las células escamosas.

En este método, desarrollado por Georges Papanicolaou [26], las células son extraídas de los tejidos tomados del cuello del útero. Esto se hace con el objetivo de diagnosticar los cambios de la célula pre-cancerosos antes de que progresen al cáncer [27]. Usando un cepillo pequeño, es tomada una muestra citológica de la cérvix y se deposita en una diapositiva delgada de vidrio. Luego, para resaltar las características de las células, la

diapositiva se mancha usando el método de Papanicolaou, enfatizando los diferentes componentes de las células con los colores específicos.

Cada muestra puede contener hasta 300000 células, vistas a través de un microscopio habilitado por citotécnicos. En la cérvix existen diferentes tipos de células localizadas en áreas separadas: área escamosa y el área columnar [27]. El área escamosa se localiza en el fondo del canal cervical y en la parte superior de la vagina (Fig. 2.1). Las células, a lo largo de la cérvix, están distribuidas en 4 capas: basal, parabasal, intermedia y la capa superficial (Fig. 2.2).





(a)

(b)

Fig. 2.2. Imágenes de la prueba de Papanicolaou. (a) Células superficiales e intermedias. (b) Células endocervicales.

Moviéndose a través de las capas, las células cambian la forma, el color y otras características. En la capa basal las células son pequeñas y redondas, con un núcleo grande y un pequeño citoplasma, mientras que a medida que se avanza a través de las capas el citoplasma se agranda y el núcleo decrece. Además, la forma general de las células se hace más oval. El área columnar se localiza en la parte superior y especialmente en el canal de cervical. Las células columnares sólo existen en la capa basal. Estas están caracterizadas por un citoplasma rectangular y un núcleo grande.

Cuando la información genética en una célula se cambia de algún modo, se convierte en una célula pre-cancerosa. En las condiciones médicas éstas son divididas en dos diagnósticos principales diferentes: displasia y carcinoma in situ. La displasia es el crecimiento desordenado o el desarrollo anormal de un tejido u órgano. Las displasias cervicales son normalmente divididas en 3 tipos: leve, moderada y severa, describiendo el riesgo de que las células se conviertan en células cancerígenas malignas, siendo la displasia leve el riesgo más bajo.

Las características de las células en la displasia dependen del tipo. En la displasia leve presentan un núcleo agrandado y ligero. Para la displasia moderada el núcleo es más grande y más oscuro, y comienza a deteriorarse. En la displasia severa el núcleo es grande, oscuro y a menudo deformado. El citoplasma es oscuro y pequeño comparado con el núcleo. Carcinoma in situ significa "cáncer en el lugar" y se caracteriza por un núcleo muy grande [28].

Clase	Categoría	Tipo de células	Cantidad	Subtotal
1	normal	escamosas superficiales	74	
2	normal	escamosas intermedias	70	242
3	normal	columnares	98	
4	anormal	escamosas con displasia leve	182	
5	anormal	escamosas con displasia moderada	146	(75
6	anormal	escamosas con displasia severa	197	075
7	anormal	escamosas intermedia con carcinoma in situ	150	

2.2 La base de imágenes Herlev de la prueba de Papanicolaou

Tabla 2.1. Base de imágenes de la prueba de Papanicolaou.



(a)



(b)



(c)



(d)



(e)



(f)



(g)

Fig. 2.3 Imágenes de la base Herlev. (a) escamosas superficiales. (b) escamosas intermedias (c) columnares (d) escamosas con displasia leve (e) escamosas con displasia moderada (f) escamosas con displasia severa. (g) escamosas intermedia con carcinoma in situ

Las imágenes utilizadas son de la base de casos de la prueba de Papanicolaou creada por el departamento de Patología del Hospital Universitario Herlev, y el departamento de Automatización en la Universidad Técnica de Dinamarca.

Esta base de imágenes está compuesta por 917 muestras distribuidas desigualmente en 7 clases diferentes (Tabla 2.1) [29]. Ejemplos de estas imágenes aparecen en la figura 2.3.

2.3 Fundamentos teóricos sobre algoritmos de segmentación de imágenes

La segmentación puede considerarse como la partición de una escena en un conjunto de regiones no solapadas, homogéneas con respecto a algún criterio cuya unión cubre la imagen completa. En otras palabras, el objetivo fundamental de la segmentación en el proceso del análisis de imágenes es el de separar los objetos de interés del resto no relevante el cual es considerado como fondo [4, 30].

La segmentación de una imagen f en l regiones es definida como el dominio de imagen Ω hacia un índice fijo I_{S_1} :

$$S_{l}(f): \Omega \mapsto I_{S_{l}} = \{1, 2 \dots, l\}$$
 (2.1)

La segmentación tiene que ser una partición del dominio [30], o sea:

$$\bigcup_{i \in I} s_i r_i = \Omega$$

$$r_i \cap r_j = \emptyset \forall i, j \in I_{s_i}$$

$$(2.2)$$

La homogeneidad es definida por un predicado de uniformidad *H*. Para una segmentación $S_{I}(f)$ cumple:

$$H(r_i) = \text{verdadero}, \forall i \in I_{s_1}$$
(2.3)

En ocasiones la segmentación suele considerase como un proceso de clasificación de los objetos presentes en una escena, y también, en cierta medida, equivale a su reconocimiento debido a que como consecuencia de la segmentación los diferentes objetos (entendidos como realizaciones físicas de clases o patrones abstractos) se encuentran perfectamente ubicados dentro de la imagen digital.

Realizar la clasificación no es trivial ya que el nivel al que se lleva a cabo esta subdivisión depende del problema a resolver y de la imagen de partida. Es por ello que se han originado diferentes técnicas de segmentación y no se conoce de la existencia de una estrategia única que pueda resolver todos los problemas que se presentan en el universo. A decir de muchos autores, la segmentación termina cuando satisfaga los intereses u objetivos del observador [30].

En cuanto a la unidad significativa que rige la segmentación, ésta suele corresponder a píxeles, regiones o contornos que muestran o disciernen una similitud en cuanto a intensidad, color, textura, gradiente local, movimiento, etc.

En general, los métodos clásicos de segmentación [30] se pueden clasificar como se indica a continuación:

- Métodos basados en la comparación con umbrales de los valores del histograma.
- Métodos basados en la detección de discontinuidades, éstos dividen la imagen a partir de cambios bruscos de los niveles de grises.
- Métodos basados en la propiedad de similitud de los valores de los niveles de grises, que permiten la agrupación de puntos a partir de ciertos criterios de homogeneidad.
- Métodos heurísticos de segmentación, los cuales se basan en el conocimiento previo de la imagen a segmentar y en la experiencia del observador, ellos incluyen en muchas ocasiones los métodos supervisados de segmentación.

2.4 Transformada Watershed



Fig. 2.4. Transformada watershed.

La transformada *Watershed* (Marcas de agua) es una herramienta morfológica que permite descubrir contornos complejos pertenecientes a los componentes de las imágenes. Este método clasifica los píxeles según su proximidad espacial, el gradiente de sus niveles de gris y la homogeneidad de sus texturas es por ello que la efectividad de la transformada *watershed* reside en que es un algoritmo de detección de contornos y de crecimiento de regiones al mismo tiempo [4, 30]. Esta transformada va a ser una imagen en escala de gris que representa la imagen topográfica de un relieve terrestre.

Las intensidades de gris de mayor amplitud se corresponden con llanuras o montañas mientras que las intensidades de menor valor se corresponden con valles y ríos. En base a estas características de las imágenes se define la técnica denominada *watershed* que, mediante la inundación de los valles y ríos, es capaz de reconocer los contornos de zonas topográficas similares, rodeadas por cadenas montañosas (Fig. 2.4).

Los huecos o cuencas del relieve (*basins*) son los sectores que acumularán el agua para sumergir la topografía y reconocer los contornos de interés.

La transformada de *watershed* se implementa utilizando como punto de partida dos tipos de algoritmos: los basados en la caída de agua (*waterfall*) y los basados en la inundación de la topografía.

La implementación que simula la caída de agua (*waterfall*) consisten en suponer que cae agua desde arriba proveniente desde la posición cada píxel de la imagen [31]. El agua de lluvia o proveniente del deshielo recorre la montaña pendiente abajo hasta llegar a los ríos inundando los valles. En estos puntos el agua no tiene dirección posible hacia abajo quedando estancada. El camino tridimensional descendiente más corto es el que tomaría el agua naturalmente. Por lo que el algoritmo *waterfall* cada píxel llena las cuencas (mínimo regional) hacia la cual el camino a realizar por el agua pendiente a bajo es el más corto.

Al finalizar el algoritmo cada píxel tiene asignada una cuenca (mínimo regional) a la cual pertenece esto permite diferenciar los diferentes componentes de las imágenes. Este procedimiento se realiza una sola vez, convirtiendo a este algoritmo en no iterativo. Sin embargo, para cada píxel es necesario determinar todos los caminos posibles hacia los mínimos regionales dentro del relieve tridimensional, lo que incrementa significativamente el costo computacional de la transformada de *watershed*.

La transformada *watershed* se aplica por lo general a tres tipos de imágenes: la imagen original en escala de grises, la imagen del gradiente y la imagen correspondiente al negativo de la transformada de distancia.

2.4.1 Mezcla de regiones pequeñas.

Los algoritmos de mezcla de regiones pequeñas surgen como una necesidad ante la aparición de segmentos "demasiado pequeños" al aplicar un algoritmo de segmentación.

El tamaño de una región "demasiado pequeña" varía de un problema a otro. Generalmente depende del tamaño de las regiones que se desean segmentar y de la resolución de las imágenes con las cuales se trabaja. En nuestro problema se considera que una región es "pequeña" si su área no supera los 32 píxeles.

En nuestro trabajo usamos el método propuesto en [4].

2.5 El algoritmo de la "caída de agua" (waterfall) para la mezcla de regiones

El algoritmo de *waterfall* [4, 32] consiste en la generación de un conjunto de particiones anidadas:

$$P^{h} = \{r_{1}^{h}, r_{2}^{h}, \dots, r_{mh}^{h}\}, h = 1, \dots, n,$$

donde se cumple que:

 $P^h \supseteq P^{h-1}$

Cada región del grupo P^h se genera de la unión de regiones de la partición P^{h-1} . De esta forma se forma se van creando las regiones de la segmentación.

El algoritmo de de *waterfall* quita los bordes de separación de todas las regiones rodeadas por bordes más altos. Las iteraciones del algoritmo de *waterfall* terminan con la separación de un solo segmento.

Waterfall produce unas zonas de base-contraste removiendo los bordes según su altura, representanda por la distancia entre los segmentos (Fig. 2.5). La implementación de *waterfall* genera otras regiones, cambiando el método de evaluación de los bordes entre las regiones.



Fig. 2.5 El algoritmo de mezcla de la "caída de agua".

En [4] se enuncia la siguiente función de similitud entre dos segmentos adyacente $r_i y r_i$:

$$E\left(\tilde{r} = r_i \cup r_j | r_i, r_j\right) = E(\tilde{r}) + E(r_i, r_j)$$

$$(2.4)$$

Donde $E(\tilde{r} = r_i \cup r_j | r_i, r_j)$ es el costo de mezclar los segmentos $r_i y r_j$, $E(\tilde{r})$ es la idoneidad de la región resultante de la mezcla y $E(r_i, r_j)$ la idoneidad para la mezcla de las dos regiones que se analizan.

$$E(r_i, r_j) = E_{bords}(r_i, r_j) E_{CMDif}(r_i, r_j)$$
(2.5)

$$E(\tilde{r}) = E_{\text{área}}(\tilde{r}) \frac{1}{E_{\text{hom}}(\tilde{r})} \sum_{c} E_{var_{c}}(\tilde{r}) \cdot (1 + |E_{conv}(\tilde{r})|)^{sign(E_{conv}(\tilde{r}))} \cdot (1 + |E_{comp}(\tilde{r})|)^{sign(E_{comp}(\tilde{r}))}$$

$$(2.6)$$

Las funciones E_{irea} , E_{hom} , E_{var} , E_{conv} y E_{comp} son funciones de energía que miden, respectivamente, la idoneidad de la región resultante en cuanto a área, homogeneidad, varianza del color, convexidad y compactación. Las funciones E_{borde} y E_{CMDif} miden la idoneidad para la mezcla del par de regiones r_i y r_j en cuanto a pendiente del borde y diferencia de color entre las dos regiones, respectivamente [4].

3.1 Medida de Vinet

La medida de *Vinet* [33] consiste en cuantificar la distancia entre dos segmentaciones A y B, buscando las regiones similares entre estas para una imagen I de N píxeles. Se estima el número de píxeles no involucrado en esta superposición, siendo entonces la medida de *Vinet* proporcional a este.

Primero, se calcula en una tabla la superposición,

$$T_{i,j} = \operatorname{card}(A_i \cap B_j), 0 \le i \le m \ y \ 0 \le j \le n$$
(3.1)

donde A_i es la *i*-ésima región de A y B_j es la *j*-ésima región de B, respectivamente, si y tienen m y n regiones. La búsqueda del primer máximo en esta tabla nos da las regiones que son prácticamente iguales, el criterio de similitud está definido por: $C_o = max(T_{i,j})$. El segundo máximo (sin tener en cuenta las dos últimas regiones) nos da el criterio de similitud C_1 , y así sucesivamente hasta obtener C_{k-1} donde k = min(m,n). C es la sucesión decreciente de la cardinalidad de las intersecciones de ambas segmentaciones tomado como un problema de asignación [34].

La medida de desigualdad entre las segmentaciones A y B está dada por:

$$D(A,B) = \frac{N-C}{N} \operatorname{con} C = \sum_{i=0}^{k-1} C_i$$
(3.2)

Una de las desventajas de esta medida es el uso de máximos locales, ya que, un cambio de un píxel en la superposición puede producir un cambio de máximo y una alta variación de la medida de desigualdad. Para resolver este problema en lugar de realizar varias iteraciones para encontrar el máximo, se utiliza el algoritmo húngaro para la asignación lineal [34, 35] que nos proporciona una configuración que minimiza la medida de desigualdad. Usando esta última técnica los cambios de un píxel tendrán una influencia pequeña en la medida.

La medida de *Vinet* se computa para cada imagen de la base de casos. Las segmentaciones consideradas son la segmentación manual y las obtenidas para cada gradiente respectivamente. Esta nos muestra la desigualdad entre lo obtenido y las segmentaciones deseadas. Los valores más bajos obtenidos en la medida, nos aseguran una mayor similitud entre las regiones de ambas segmentaciones.

3.2 Selección de los rasgos de textura que mejor describen las regiones en las imágenes de la prueba de Papanicolau

Para medir el poder discriminante de cada una de los rasgos de textura se usó un método estadístico conocido como Análisis Discriminante [36]. Para ello se seleccionó una muestra de 49 imágenes, 7 por clase (Tabla3.1). El análisis discriminante se llevó a cabo usando un método de inclusión por pasos mediante el estadígrafo lambda de *Wilks* [36] del SPSS 16.0.

La lambda de Wilks se calcula como:

$$\Lambda = \frac{|W|}{|W+B|} \tag{3.3}$$

donde:

W: Matriz de suma de cuadrados intra-grupos.

B: Matriz de suma de cuadrados inter-grupos.

El estadígrafo Λ toma valores entre 0 y 1. Valores cercanos a 0 indican mayor poder discriminante de las variables consideradas y valores cercanos a 1 indican menor poder discriminante.

Los resultados completos del análisis discriminante se muestran en el anexo 1.

Variables Incluídas/Extraídas ^{a,b,c,d}										
		Lambda de Wilks								
0	uída					F exacta				
Pas	Incl	Estadígrafo	gl1	gl2	gl3	Estadígrafo	gl1	gl2	Sig.	
1	H6	.373	1	2	144	120.957	2	144	.000	
2	H12	.260	2	2	144	68.619	4	286	.000	
3	H1	.198	3	2	144	59.098	6	284	.000	
4	H8	.169	4	2	144	50.412	8	282	.000	
5	H7	.152	5	2	144	43.800	10	280	.000	
En cada ite	ración s	se incluye la va	riable	que mi	nimice	la lambda de \	Nilk.			
a. Máximo r	a. Máximo número de pasos: 26									
b. F parcial mínima para incluir: 3.84.										
c. F parcial	máxima	a para extraer:	2.71.							
d. gl: grado:	s de libe	ertad.								

Tabla 3.1 Resultados del análisis discriminante

3.3 Medidas de similitud

Las medidas de similitud usadas en este trabajo se enuncian a continuación. Para ello se usó la siguiente notación:

 $H_i = \{H_{1i}, H_{2i}, \dots, H_{13i}\}$: Vector normalizado de los trece rasgos descritos en la sección 1.4.

II Norma euclideana.

 $\overline{Lab_i}$: Media de los colores de la región *i* en el espacio de colores Lab.

 \overline{RGB}_{i} : Media de los colores de la región *i* en el espacio de colores RGB.

 $E(R_i \cup R_j)$: Ver ecuación (2.6).

 $E(R_i, R_j)$: Ver ecuación (2.5).

$$S_{1}(R_{i}, R_{j}) = \|\overline{H_{i}} - \overline{H_{j}}\| = \sqrt{\sum_{k=1}^{13} (H_{ki} - H_{kj})^{2}}$$
(3.4)

$$S_2(R_i, R_j) = \left\| \overline{H_i} - \overline{H_j} \right\| + \left\| \overline{RGB_i} - \overline{RGB_j} \right\|$$
(3.5)

$$S_{3}(R_{i}, R_{j}) = \left\| \overline{H_{i}} - \overline{H_{j}} \right\| + \left\| \overline{Lab_{i}} - \overline{Lab_{j}} \right\|$$
(3.6)

$$S_4(Ri,Rj) = E(Ri \cup Rj) + E(Ri,Rj) \cdot \left\|\overline{H_i} - \overline{H_j}\right\|$$
(3.7)

$$S_{5}(R_{i}, R_{j}) = \|\overline{H}_{i}^{*} - \overline{H}_{j}^{*}\| = \sqrt{\sum_{k \in \{1, 6, 7, 8, 12\}} (H_{ki} - H_{kj})^{2}}$$
(3.8)

$$S_6(R_i, R_j) = \left\| \overline{H_i^*} - \overline{H_j^*} \right\| + \left\| \overline{RGB_i} - \overline{RGB_j} \right\|$$
(3.9)

$$S_{7}(R_{i},R_{j}) = \left\|\overline{H_{i}^{*}} - \overline{H_{j}^{*}}\right\| + \left\|\overline{Lab_{i}} - \overline{Lab_{j}}\right\|$$
(3.10)

$$S_{8}(R_{i},R_{j}) = E(\tilde{r} = r_{i} \cup r_{j}|r_{i},r_{j}) = E(\tilde{r}) + E(r_{i},r_{j}) \cdot \left\|\overline{H_{i}^{*}} - \overline{H_{j}^{*}}\right\|$$
(3.11)

3.4 Resultados

En los experimentos realizados, se usó la medida de similitud reportada en [4] y expuesta en la sección 2.5. A esta medida de similitud se le llamó S_9 . El esquema de los experimentos realizados se muestra en la figura 3.1. La transformada watershed de aplicó sobre el gradiente de DiZenzo [33]. Se utilizaron un total de 21 imágenes, 3 de cada clase.



Fig. 3.1 Experimento para medir la calidad de las mezclas usando las nueve funciones que se estudian.

La figura 3.2 muestra un diagrama de cajas con los resultados obtenidos.

Desde el punto de vista puntual, los mejores resultados se obtuvieron usando la combinación de las funciones reportadas en [4] con los rasgos de textura. Los resultados para la medida S_9 también estuvieron dentro de los mejores. El uso de una selección de los rasgos de Haralick (S_5 , S_6 , S_7 y S_8) mejoró los resultados con respecto al uso de los 13 rasgos iniciales (S_1 , S_2 , S_3 y S_4).



Fig. 3.2 Diagrama de cajas con los resultados obtenidos para cada medida de similitud.

Para comprobar si estas diferencias puntuales son estadísticamente significativas se utilizaron las pruebas de Friedman y la prueba de Duncan-Sidak como prueba post hoc [37]. Como paquete estadístico se utilizó la toolbox Statistics v7.6.

La figura 3.3 muestra el resultado de la prueba de Duncan-Sidak para la función de similitud entre regiones S_8 .

```
>> [p,table,stats] = friedman(tabla,1)
p =
  2.7151e-010
table =
    'Source'
                                   'df'
                                          'MS'
                                                         'Chi-sq'
                                                                      'Prob>Chi-sq'
                 'SS'
    'Columns'
                 [ 390.1190]
                                [ 8] [48.7649]
                                                                     [2.7151e-010]
                                                       [61.1951]
                 [ 680.8810] [160] [ 4.2555]
[1.0710e+003] [188] []
    'Error'
                                                               []
                                                                                  []
    'Total'
                                                                                  []
                                                                []
stats =
       source: 'friedman'
           n: 21
    meanranks: [5.5714 6.2381 6.2381 2.9762 5.3810 6.2381 6.2381 2.6429 3.4762]
        sigma: 2.5249
```

>> [c,m,h,gnames] = multcompare(stats,'ctype','dunn-sidak')

с =

1.0000	2.0000	-3.1521	-0.6667	1.8188
1.0000	3.0000	-3.1521	-0.6667	1.8188
1.0000	4.0000	0.1098	2.5952	5.0807
1.0000	5.0000	-2.2950	0.1905	2.6759
1.0000	6.0000	-3.1521	-0.6667	1.8188
1.0000	7.0000	-3.1521	-0.6667	1.8188
1.0000	8.0000	0.4431	2.9286	5.4140
1.0000	9.0000	-0.3902	2.0952	4.5807
2.0000	3.0000	-2.4855	0	2.4855
2.0000	4.0000	0.7764	3.2619	5.7474
2.0000	5.0000	-1.6283	0.8571	3.3426
2.0000	6.0000	-2.4855	0	2.4855
2.0000	7.0000	-2.4855	0	2.4855
2.0000	8.0000	1.1098	3.5952	6.0807
2.0000	9.0000	0.2764	2.7619	5.2474
3.0000	4.0000	0.7764	3.2619	5.7474
3.0000	5.0000	-1.6283	0.8571	3.3426
3.0000	6.0000	-2.4855	0	2.4855
3.0000	7.0000	-2.4855	0	2.4855
3.0000	8.0000	1.1098	3.5952	6.0807
3.0000	9.0000	0.2764	2.7619	5.2474
4.0000	5.0000	-4.8902	-2.4048	0.0807
4.0000	6.0000	-5.7474	-3.2619	-0.7764
4.0000	7.0000	-5.7474	-3.2619	-0.7764
4.0000	8.0000	-2.1521	0.3333	2.8188
4.0000	9.0000	-2.9855	-0.5000	1.9855
5.0000	6.0000	-3.3426	-0.8571	1.6283
5.0000	7.0000	-3.3426	-0.8571	1.6283
5.0000	8.0000	0.2526	2.7381	5.2236
5.0000	9.0000	-0.5807	1.9048	4.3902
6.0000	7.0000	-2.4855	0	2.4855
6.0000	8.0000	1.1098	3.5952	6.0807
6.0000	9.0000	0.2764	2.7619	5.2474
7.0000	8.0000	1.1098	3.5952	6.0807
/.0000	9.0000	0.2764	2.7619	5.2474
8.0000	9.0000	-3.3188	-0.8333	1.6521

m =

5.5714	0.5510
6.2381	0.5510
6.2381	0.5510
2.9762	0.5510
5.3810	0.5510
6.2381	0.5510
6.2381	0.5510
2.6429	0.5510
3.4762	0.5510

h =

1

gnames =



Fig. 3.3 Resultado de la prueba de Duncan-Sidak para la función de similitud entre regiones S₈.

Como se observa en la figura 3.3 los resultados después de la inclusión de los rasgos de Haralick no son significativamente mejores a la misma función de similitud cuando no usa rasgos de textura. A partir de estas pruebas solo podemos asegurar que la función de similitud S_8 no es significativamente mejor que S_4 y S_9 aunque sí lo es con respecto a todas las demás.

CONCLUSIONES

Con el presente trabajo se llegó a las siguientes conclusiones:

- 1. Se implementaron funciones de similitud para la mezcla de regiones utilizando rasgos de textura.
- Se realizó un estudio sobre cuáles son los rasgos de textura que mejor caracterizan a las regiones de las imágenes de la prueba de Papanicolaou. Los rasgos de Haralick que mejor caracterizan a las regiones en este tipo de imágenes fueron:
 - a. Segundo Momento angular (ASM).
 - b. Suma de Promedio.
 - c. Suma de Varianza.
 - d. Suma de Entropía.
 - e. Información del coeficiente de Correlación.
- 3. Los rasgos de textura que intervinieron en el estudio (los 13 rasgos de Haralick) no mejoraron significativamente los resultados con respeto a cuando no se usaron.

Para dar continuidad a este trabajo se hacen las siguientes recomendaciones:

- 1. Realizar los mismos experimentos utilizando otros rasgos de textura, p. e. mediante el uso de filtros de Gabor.
- 2. Seleccionar rasgos utilizando otro método estadístico.

REFERENCIAS BIBLIOGRÁFICAS

- [1] T. Mäenpää, *The Local Binary Pattern Approach to Texture Analysis: Extensions and Applications*: Oulun yliopisto, 2003.
- [2] L. Vincent and P. Soille, "Watersheds in digital spaces: an efficient algorithm based on immersion simulations," *IEEE transactions on pattern analysis and machine intelligence*, vol. 13, pp. 583-598, 1991.
- [3] M. Gonzalez, "Segmentación morfológica watershed en imágenes médicas: métodos de selección de marcadores," Tesis Doctoral. Universidad Nacional de Mar del Plata, 2008.
- [4] T. Geerinck, "Visual Attention Framework: Aplication to Event Analysis," in *Department of Electronics and Informatics (ETRO)*: Vrije Universiteit Brussel, 2009.
- [5] A. A. Bell, G. Herberich, D. Meyer-Ebrecht, A. Bocking, and T. Aach, "Segmentation and detection of nuclei in silver stained cell specimens for early cancer diagnosis," in *Image Processing*, 2007. ICIP 2007. IEEE International Conference on, 2007, pp. VI-49-VI-52.
- [6] D. Svoboda, M. Kozubek, and S. Stejskal, "Generation of digital phantoms of cell nuclei and simulation of image formation in 3d image cytometry," *Cytometry part A*, vol. 75, pp. 494-509, 2009.
- [7] F. Moussavi, G. Heitz, F. Amat, L. R. Comolli, D. Koller, and M. Horowitz, "3D segmentation of cell boundaries from whole cell cryogenic electron tomography volumes," *Journal of structural biology*, vol. 170, pp. 134-145, 2010.
- [8] O. Louchet and C.-C. Lenglet-Cacile, "Wavelet-Based Texture Classification and Retrieval," 2003.
- [9] R. M. Haralick, K. Shanmugam, and I. H. Dinstein, "Textural features for image classification," *Systems, Man and Cybernetics, IEEE Transactions on*, pp. 610-621, 1973.
- [10] G. R. Cross and A. K. Jain, "Markov random field texture models," *Pattern Analysis and Machine Intelligence, IEEE Transactions on,* pp. 25-39, 1983.

- [11] A. K. Jain and K. Karu, "Learning texture discrimination masks," *Pattern Analysis* and Machine Intelligence, IEEE Transactions on, vol. 18, pp. 195-205, 1996.
- [12] A. Rao, & Lohse, G., *Identifying High-Level Features Of Texture Perception.*, 1993.
- [13] H. Tamura, S. Mori, and T. Yamawaki, "Textural features corresponding to visual perception," *Systems, Man and Cybernetics, IEEE Transactions on*, vol. 8, pp. 460-473, 1978.
- [14] P. Hiremath and S. Shivashankar, "Wavelet based features for Texture Classification," *GVIP journal*, vol. 6, pp. 55-58, 2006.
- [15] J. S. Weszka, C. R. Dyer, and A. Rosenfeld, "A comparative study of texture measures for terrain classification," *Systems, Man and Cybernetics, IEEE Transactions on*, pp. 269-285, 1976.
- [16] M. Unser, "Sum and difference histograms for texture classification," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, pp. 118-125, 1986.
- [17] B. Julesz, "Textons, the elements of texture perception, and their interactions," *Nature*, 1981.
- [18] J. Beck, "Textural segmentation, second-order statistics, and textural elements," *Biological Cybernetics*, vol. 48, pp. 125-130, 1983.
- [19] R. Sánchez-Yánez, E. V. Kurmyshev, and F. J. Cuevas, "A framework for texture classification using the coordinated clusters representation," *Pattern Recognition Letters*, vol. 24, pp. 21-31, 2003.
- [20] R. Chellappa and B. Manjunath, "Texture classification and segmentation," *KLUWER INTERNATIONAL SERIES IN ENGINEERING AND COMPUTER SCIENCE*, pp. 219-240, 2001.
- [21] R. Chellappa, Kashyap, R., & Manjunath, B., *Model-Based Texture Segmentation And Classification.*, 2nd edition. ed. Singapore, 1999.
- [22] O. Faugeras, "Texture analysis and classification using a human visual model," in *Proc. IEEE Internat. Conf. on Pattern Recognition*, 1978, pp. 549-552.
- [23] G. Granlund, In Search Of A General Picture Processing Operator, 1978.
- [24] B. S. Manjunath and W.-Y. Ma, "Texture features for browsing and retrieval of image data," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 18, pp. 837-842, 1996.
- [25] M. Hall-Beyer, "GLCM texture: a tutorial," *National Council on Geographic Information and Analysis Remote Sensing Core Curriculum*, 2000.
- [26] G. N. Papanicolaou and H. F. Traut, "Diagnosis of uterine cancer by the vaginal smear," *New York*, p. 46, 1943.
- [27] A. Meisels, C. Morin, D. Giri, and R. S. Hoda, "Cytopathology of the uterus," *International Journal of Gynecologic Pathology*, vol. 17, p. 286, 1998.

- [28] E. Martin, "Pap-smear classification," *Master's Thesis, Technical University of Denmark, Oersted-DTU, Automation,* 2003.
- [29] P. Soille and M. Pesaresi, "Advances in mathematical morphology applied to geoscience and remote sensing," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 40, pp. 2042-2055, 2002.
- [30] I. Vanhamel, "Vector valued nonlinear diffusion and its application to image segmentation.," in *Faculty of Engineering Sciences, Electronics and Informatics (ETRO).* Brussels, Belgium: Vrije Universiteit Brussel, 2006.
- [31] J. Facon, Morfología Matemática. Teoría y ejemplos. Curitiba Brasil, 1996.
- [32] S. Beucher, "Watershed, hierarchical segmentation and waterfall algorithm," in *Mathematical morphology and its applications to image processing*: Springer, 1994, pp. 69-76.
- [33] M. Orozco-Monteagudo, H. Sahli, C. Mihai, and A. Taboada-Crispi, "A hybrid approach for Pap-Smear cell nucleus extraction," in *Pattern Recognition*: Springer, 2011, pp. 174-183.
- [34] E. V. Luciano, J. M. Meriga, A. M. Gil-Lafuente, and S. B. Reverta, "OWA Operators in the Assignment Process: The Case of the Hungarian Algorithm," in *Modeling and Simulation in Engineering, Economics and Management*: Springer, 2012, pp. 166-177.
- [35] H. W. Kuhn, "The Hungarian method for the assignment problem," *Naval research logistics quarterly*, vol. 2, pp. 83-97, 1955.
- [36] C. J. Huberty, *Applied discriminant analysis*: Wiley New York, 1994.
- [37] M. Hollander and D. A. Wolfe, *Nonparametric statistical methods*: Hoboken, NJ: John Wiley & Sons, Inc., 1999.

ANEXO 1

Resultados completos del análisis discriminante que se describe en la sección 3.2.

Discriminant

	Analysis case Frocessing St	unnary	
Unweighted	Cases	Ν	Percent
Valid		147	100.0
Excluded	Missing or out-of-range group codes	0	.0
	At least one missing discriminating variable	0	.0
	Both missing or out-of-range group codes and at least one missing discriminating variable	0	.0
	Total	0	.0
Total		147	100.0

Analysis Case Processing Summary

Group Statistics

- 37

		Valid N (listwise)		
class		Unweighted	Weighted	
1	V1	49	49.000	
	V2	49	49.000	
	V3	49	49.000	
	V4	49	49.000	
	V5	49	49.000	
	V6	49	49.000	
	V7	49	49.000	
	V8	49	49.000	
	V9	49	49.000	
	V10	49	49.000	
	V11	49	49.000	
	V12	49	49.000	
	V13	49	49.000	
2	V1	49	49.000	
	V2	49	49.000	
	V3	49	49.000	
	V4	49	49.000	
	V5	49	49.000	
	V6	49	49.000	
	V7	49	49.000	
	V8	49	49.000	
	V9	49	49.000	
	V10	49	49.000	

- 38

	V11	49	49.000
	V12	49	49.000
	V13	49	49.000
3	V1	49	49.000
	V2	49	49.000
	V3	49	49.000
	V4	49	49.000
	V5	49	49.000
	V6	49	49.000
	V7	49	49.000
	V8	49	49.000
	V9	49	49.000
	V10	49	49.000
	V11	49	49.000
	V12	49	49.000
	V13	49	49.000
Total	V1	147	147.000
	V2	147	147.000
	V3	147	147.000
	V4	147	147.000
	V5	147	147.000
	V6	147	147.000
	V7	147	147.000
	V8	147	147.000
	V9	147	147.000

V10	147	147.000
V11	147	147.000
V12	147	147.000
V13	147	147.000

Analysis 1 Stepwise Statistics

Variables Entered/Removed^{a,b,c,d}

		Wilks' Lambda							
						Exact F			
Step	Entered	Statistic	df1	df2	df3	Statistic	df1	df2	Sig.
1	V6	.373	1	2	144.000	120.957	2	144.000	.000
2	V12	.260	2	2	144.000	68.619	4	286.000	.000
3	V1	.198	3	2	144.000	59.098	6	284.000	.000
4	V8	.169	4	2	144.000	50.412	8	282.000	.000
5	V7	.152	5	2	144.000	43.800	10	280.000	.000

At each step, the variable that minimizes the overall Wilks' Lambda is entered.

a. Maximum number of steps is 26.

b. Minimum partial F to enter is 3.84.

c. Maximum partial F to remove is 2.71.

d. F level, tolerance, or VIN insufficient for further computation.

40

Variables in the Analysis						
Step		Tolerance	F to Remove	Wilks' Lambda		
1	V6	1.000	120.957			
2	V6	.987	92.748	.598		
	V12	.987	30.962	.373		
3	V6	.987	91.497	.453		
	V12	.744	47.765	.331		
	V1	.751	22.472	.260		
4	V6	.847	34.908	.253		
	V12	.543	7.443	.187		
	V1	.190	27.006	.234		
	V8	.146	11.846	.198		
5	V6	.846	30.195	.218		
	V12	.534	6.732	.167		
	V1	.145	15.783	.186		
	V8	.093	9.804	.173		
	V7	.436	7.943	.169		

Variables Not in the Analysis

Step		Tolerance	Min. Tolerance	F to Enter	Wilks' Lambda
0	V1	1.000	1.000	9.593	.882
	V2	1.000	1.000	2.036	.972
	V3	1.000	1.000	23.732	.752
	V4	1.000	1.000	54.393	.570
	V5	1.000	1.000	4.432	.942
	V6	1.000	1.000	120.957	.373

- 41

-			_	L	
	V7	1.000	1.000	54.894	.567
	V8	1.000	1.000	41.641	.634
	V9	1.000	1.000	30.342	.704
	V10	1.000	1.000	3.505	.954
	V11	1.000	1.000	4.492	.941
	V12	1.000	1.000	48.371	.598
	V13	1.000	1.000	20.953	.775
1	V1	.997	.997	9.141	.331
	V2	1.000	1.000	1.367	.366
	V3	.983	.983	5.184	.348
	V4	.984	.984	26.695	.272
	V5	1.000	1.000	4.160	.353
	V7	.985	.985	27.154	.270
	V8	.992	.992	11.210	.323
	V9	.981	.981	8.148	.335
	V10	.999	.999	.986	.368
	V11	.999	.999	1.953	.363
	V12	.987	.987	30.962	.260
	V13	.999	.999	8.919	.332
2	V1	.751	.744	22.472	.198
	V2	.902	.892	3.160	.249
	V3	.919	.919	.649	.258
	V4	.699	.699	8.151	.234
	V5	.966	.954	5.873	.240
	V7	.701	.701	8.445	.233

- 42

					_
	V8	.578	.575	7.939	.234
	V9	.829	.829	10.104	.228
	V10	.898	.887	1.737	.254
	V11	.929	.917	3.224	.249
	V13	.310	.306	20.594	.202
3	V2	.902	.694	2.002	.192
	V3	.883	.722	1.685	.193
	V4	.683	.601	9.750	.174
	V5	.552	.429	.878	.195
	V7	.686	.602	9.925	.173
	V8	.146	.146	11.846	.169
	V9	.186	.168	11.768	.169
	V10	.884	.706	.419	.197
	V11	.649	.525	.801	.196
	V13	.175	.175	2.671	.191
4	V2	.893	.145	1.256	.166
	V3	.804	.133	.071	.169
	V4	.434	.093	7.851	.152
	V5	.552	.146	.697	.168
	V7	.436	.093	7.943	.152
	V9	.006	.005	6.612	.155
	V10	.882	.146	.560	.168
	V11	.640	.144	.279	.169
	V13	.173	.145	3.255	.162
5	V2	.890	.092	1.426	.149

				-
V3	.773	.081	.458	.151
V4	.001	.001	7.851	.152
V5	.551	.093	.737	.150
V9	.006	.004	2.954	.146
V10	.853	.092	1.114	.150
V11	.633	.093	.146	.152
V13	.157	.087	2.507	.147

				Wilks' La	ambda				
							Exa	ct F	
Step	Number of Variables	Lambda	df1	df2	df3	Statistic	df1	df2	Sig.
1	1	.373	1	2	144	120.957	2	144.000	.000
2	2	.260	2	2	144	68.619	4	286.000	.000
3	3	.198	3	2	144	59.098	6	284.000	.000
4	4	.169	4	2	144	50.412	8	282.000	.000
5	5	.152	5	2	144	43.800	10	280.000	.000

Summary of Canonical Discriminant Functions

				Canonical
Function	Eigenvalue	% of Variance	Cumulative %	Correlation
1	3.179 ^a	84.7	84.7	.872
2	.573 ^a	15.3	100.0	.604

a. First 2 canonical discriminant functions were used in the analysis.

44

Wilks' Lambda

Test of Function(s)	Wilks' Lambda	Chi-square	df	Sig.
1 through 2	.152	267.438	10	.000
2	.636	64.363	4	.000

Standardized Canonical Discriminant Function Coefficients

	Function				
	1	2			
V1	1.209	.663			
V6	.598	480			
V7	201	.747			
V8	1.301	310			
V12	401	338			

Functions at Group Centroids

	Function		
class	1	2	
1	-2.239	.468	
2	.165	-1.058	
3	2.074	.589	

Unstandardized canonical discriminant functions evaluated at group means

- 45

Structure Matrix		
	Function	
	1	2
V6	.705 [*]	419
V4 ^a	.456 [*]	.424
V7	.455 [*]	.428
V12	447 [*]	251
V8	.412 [*]	259
V13 ^a	.371 [*]	123
V3 ^a	.321 [*]	148
V10 ^a	.157 [*]	.069
V2 ^a	.100 [*]	.052
V1	038	.474 [*]
V9 ^a	.300	433 [*]
V5 ^a	.048	.409 [*]
V11 ^a	.068	253 [*]

Pooled within-groups correlations between discriminating variables and standardized canonical discriminant functions

Variables ordered by absolute size of correlation within function.

*. Largest absolute correlation between each variable and any

discriminant function

a. This variable not used in the analysis.

46