

Identificación de displasias en análisis de muestras de Papanicolaou usando ACO.

Maricela Gress-Roldán¹, Edmundo Bonilla-Huerta², Roberto Morales-Caporal³ y José Crispín Hernández-Hernández⁴.

^{1,2,3,4} Laboratorio de Investigación en Tecnologías Inteligentes,

Instituto Tecnológico de Apizaco,

Apizaco, Tlaxcala, México

{maricela,edbonn,moralescaporal}@itapizaco.edu.mx, josechh@yahoo.com

Paper received on 30/07/12, Accepted on 16/08/12.

Resumen. El Papanicolaou es una prueba muy sencilla, la desventaja es que esta sujeta a errores a la hora de la interpretación de las muestras durante su observación en el microscopio, debido a esta problemática se han desarrollado herramientas de cómputo, donde la etapa de segmentación llega a ser una de las etapas más importantes y difíciles durante el proceso de identificación de las imágenes. En este artículo se presenta una metodología que se apoya en el Procesamiento Digital de Imágenes (PDI) y el algoritmo de Optimización por Colonia de Hormigas (ACO por sus siglas en inglés) para identificar y extraer las características más importantes de las células examinadas con la finalidad de obtener una tasa de reconocimiento satisfactoria.

Palabras Clave: Procesamiento Digital de Imágenes, Citología, ACO, reconocimiento automático.

1 Introducción.

El cáncer cérvicouterino (CaCu) afecta el sistema reproductivo de la mujer. La causa predominante de éste se debe a ciertos derivados del virus del papiloma humano (VPH), una de varias enfermedades venéreas. Por lo general, el sistema inmunológico del organismo evita que el virus afecte de forma grave al sistema reproductor, sin embargo en algunos casos éste logra sobrevivir el suficiente tiempo para afectar las células localizadas en la superficie del cérvix, transformándolas en cancerígenas. Cerca del 50% de los casos de cáncer cérvico se da en mujeres cuya edad va de los 35 a los 55 años [9].

El CaCu es el resultado de un proceso dinámico que se inicia probablemente a partir de una infección viral, aunada a factores de riesgo, pasando por una etapa pre invasora. Este proceso es asintomático y de evolución muy lenta, lo que permite diagnosticar y tratar oportunamente este padecimiento. El CaCu tiene una evolución bien identificada, con la presencia de lesiones precursoras denominadas displasias, las cuales se clasifican en leves, moderadas y severas, según la gravedad de las alteraciones.

2 Estado del arte.

El uso de herramientas computacionales en la medicina es un tema de suma importancia hoy en día, los análisis de muestras de Papanicolaou han sido un problema que se ha tratado de atacar en muchos trabajos utilizando diferentes técnicas de visión artificial, por ejemplo en 2009, Gallegos [3] buscó clasificar el tipo de células y obtuvo como resultado el 76.0% utilizando el método Naive Bayes, y del 83.2% de precisión con la red Perceptrón Multicapa. A principios de 2011, Pérez [4] trató de resolver el problema de segmentación de imágenes de células con Sobel. Los resultados fueron aceptables ya que de las 60 imágenes de prueba, fueron segmentadas correctamente 54, que es una tasa de segmentación del 90 %.

En el artículo presentado por F. Gallegos-Funes [5] en el año de 2009, se usó una red neuronal con la función de base radial tipo M para el proceso de reconocimiento automático de muestras de Papanicolaou. Las características extraídas fueron área, perímetro, circularidad, relación núcleo/citoplasma y finalmente los valores máximos y mínimos de brillo en el núcleo. Los resultados muestran que la red obtuvo 20% de error.

Durante el presente año se han desarrollado proyectos donde podemos encontrar el de I. Muhammah [6] quien ha desarrollado una metodología basada en Clustering fuzzy C-Means. Los resultados de clasificación arrojaron los resultados en la tasa de sensibilidad de 90.86% y una tasa de especificación de 81.62% en comparación con el experto. En el artículo donde B. Mahanta [7] presentó una metodología capaz de extraer las características que le interesa a los patólogos (tamaño del núcleo, forma del núcleo y distribución del núcleo celular). A partir de las imágenes binarizadas se logró obtener cada una de las características buscadas.

El método de Ant Colony Optimization para segmentación de imágenes ha sido probado por algunos autores quienes han demostrado que este algoritmo resulta ser una buena alternativa para una de las tareas más difíciles en las etapas de la visión artificial.

Tian [8] en el año 2008 planteó una solución a base de segmentación de imágenes por medio de Optimización por Colonia de Hormigas (ACO). Y en 2010, Baterina [2] propuso extraer los bordes de imágenes utilizando ACO (Ant Colony Optimization), ya que la segmentación basada en ACO, donde afirmaron que este algoritmo tiene el potencial de superar las limitaciones de los métodos convencionales. Los resultados se que se obtuvieron fueron satisfactorios, y el tiempo de respuesta fue de 3 segundos.

3 Metodología.

La metodología propuesta se muestra en el diagrama de la figura 1, posteriormente se describe cada una de las etapas que la componen.

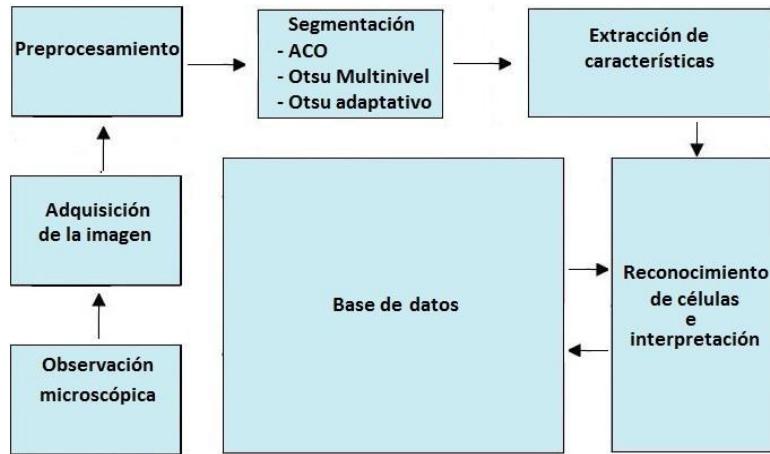


Figura 1. Metodología propuesta.

3.1 Adquisición de la imagen.

Para realizar el análisis es necesario digitalizar las muestras, las imágenes fueron obtenidas de un banco de imágenes proporcionadas por el Instituto Mexicano del Seguro Social (IMSS) del laboratorio de citología del Hospital General de zona No.1, Tlaxcala, las imágenes son de formato JPG, tomadas con zoom óptico que varía de 40x a 100x con dimensión de 2592 X 1944 píxeles.

3.2 Preprocesamiento.

En primer lugar se busca eliminar la sobre-iluminación que se encuentra en el área de interés haciendo una resta de imágenes (original menos imagen del escenario sin célula), posteriormente la imagen se convierte a formato de color Lab donde se elige el canal de color L que muestra las imágenes de manera más clara y definida, y se realiza una mejora de la imagen usando un filtro de punto medio [11].

3.3 Segmentación.

El objetivo de la segmentación es obtener una partición de la imagen en regiones coherentes como paso previo al análisis de su contenido. En este artículo se propone el uso del algoritmo ACO que consiste en las siguientes etapas (ver figura 2).

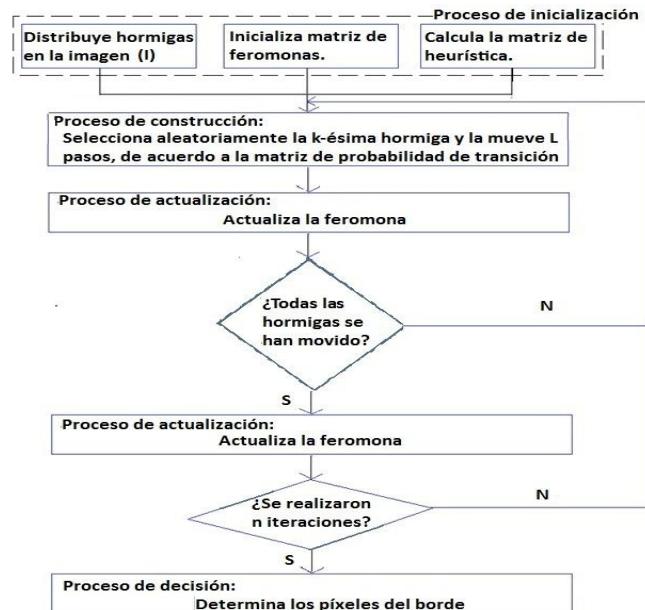


Figura 2. Diagrama descriptivo de ACO.

Las fórmulas y valores asignados para cada una de las etapas se describen a continuación:

***Proceso de inicialización:** Esta etapa se compone de las siguientes sub etapas:

* *Distribuye las hormigas en la imagen:* La distribución de las hormigas se realiza de manera aleatoria, sobre toda la imagen. El número de hormigas que se distribuyen en la imagen se calcula de la siguiente manera:

$$K = \sqrt{M1 \cdot M2} \quad (1)$$

Donde:

- M1=Largo de la imagen.
- M2=Ancho de la imagen.

* *Inicializa matriz de feromonas:* Se inicializa la matriz de las feromonas, con un valor fijado por el usuario, el valor asignado en este trabajo a esta constante se muestra en la tabla 1.

*Calcula la matriz heurística:

$$n_{i,j} = \frac{1}{Z} V_c(I_{i,j}) \quad (2)$$

Donde:

- $Z = \sum_{i=1}^{M1} \sum_{j=1}^{M2}$
- $I_{i,j}$ = valor de intensidad del pixel en su posición (i,j).
- $V_c(I_{i,j})$ = función de un grupo local de píxeles (vecinos), su valor depende de las variaciones de los valores de intensidad de la imagen.

*Proceso de construcción: En este proceso una hormiga es aleatoriamente seleccionada de k hormigas, esta hormiga será consecutivamente movida sobre la imagen por L pasos o movimientos. Estas hormigas se mueven del nodo (l,m) a su nodo vecino (i,j) de acuerdo a la probabilidad de transición dada por:

$$P_{(l,m),(i,j)}^n = \frac{(T_{i,j}^{(n-1)})^\alpha (\eta_{i,j})^\beta}{\sum_{(i,j) \in \Omega(l,m)} (T_{i,j}^{(n-1)})^\alpha (\eta_{i,j})^\beta} \quad (3)$$

Donde:

- $T_{i,j}^{(n-1)}$ = Valor de la feromona en el nodo (i,j).
- $\Omega(l,m)$ = Es la vecindad de nodos del nodo (l,m).
- $\eta_{i,j}$ = Información heurística del nodo (i,j)
- α Y β = La influencia de la matriz de feromonas y la matriz heurística.

*Proceso de actualización: En esta etapa se lleva a cabo dos operaciones para actualizar la matriz de feromonas. La primera actualización se realiza después del movimiento de cada hormiga dentro de cada paso de construcción. Cada componente de la matriz de feromonas es actualizado de acuerdo a:

$$T_{i,j}^{(n-1)} = \begin{cases} (1 - \rho) \cdot T_{i,j}^{(n-1)} + \rho \cdot \Delta_{i,j}^{(k)} & \text{Si } (i,j) \text{ es visitado por la } k\text{-} \\ & \text{ésima hormiga actual.} \\ T_{i,j}^{(n-1)} & \text{En otro caso} \end{cases} \quad (4)$$

Donde:

- ρ = tasa de evaporación de la feromona.
- $\Delta_{i,j}^{(k)}$ = $\eta_{i,j}$ es determinada por la matriz de heurística.

La segunda actualización es llevada a cabo después del movimiento de todas las hormigas dentro de cada paso de construcción de acuerdo a:

$$T^{(n)} = (1 - \varphi) \cdot T^{(n-1)} + \varphi \cdot T^{(0)} \quad (5)$$

Donde:

- φ es el coeficiente de decadencia de la feromonas.

***Proceso de decisión:** En este paso, se realiza un proceso de decisión binario en cada píxel para determinar si éste es un borde o no, por la aplicación de un umbral (T) en la matriz final de feromonas. El umbral (T) es determinado por el cálculo de la media de los valores del píxel de la imagen, el cálculo se realiza a través del histograma de la imagen.

$$E_{i,j} = \begin{cases} 1, & \text{Si } T_{i,j}^{(N)} \geq T' \\ 0 & \text{En otro caso} \end{cases} \quad (6)$$

Una vez encontrada la región del citoplasma, se calculan sus coordenadas dentro de la imagen, esto con la finalidad de realizar posteriormente la detección de color en el área de interés. Los parámetros utilizados en ACO para segmentar las imágenes fueron elegidos de acuerdo a los resultados obtenidos en pruebas previamente realizadas, y son los siguientes (ver tabla 1):

Tabla 1. Parámetros utilizados en ACO

Parámetro	Cantidad
Número de hormigas	141
Valor inicial de la feromonas	0.0000001
Factor de peso de la información de la feromonas	1
Factor de peso de la información heurística.	1
Conectividad de la vecindad	8
Tasa de evaporación de la feromonas	0.1
Decadencia del coeficiente de feromonas	0.05
Número de movimientos de las hormigas en cada paso de construcción	60

3.4 Extracción de características.

En esta etapa el objetivo es extraer las características más importantes del núcleo y citoplasma (área, perímetro, circularidad, relación núcleo/citoplasma [10] y color)

Por ello en la metodología propuesta para determinar el color de la célula, se extraen los valores del tono en la imagen original. Posteriormente se calcula la longitud de onda dominante comparando el valor del píxel con el valor asignado a cada uno de los colores que forman parte del espectro de color visible en el que se descompone la luz blanca.

3.5 Reconocimiento de células e interpretación.

Se utiliza una red neuronal de retropropagación, en la cual, la capa de entrada será del tamaño de número de características obtenidas, mientras que la capa de salida consta de 6 neuronas que corresponden al número de clases a las que puede pertenecer la célula, mientras que para la capa intermedia se realizaron pruebas con diferentes número de neuronas, considerando la que obtiene mejores resultados.

4 Resultados.

Imagen original. Las imágenes fueron catalogadas previamente por un citotecnólogo de la siguiente manera: cáncer in situ, carcinoma invasor, displasias graves, displasias moderadas, displasias leves. En la figura 3 se muestran dos imágenes de ejemplo (denominadas muestra 1 y 2 respectivamente) donde se observa la sobre-iluminación en el área de interés (célula).

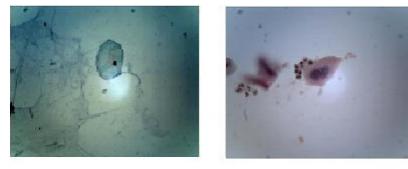


Figura 3. Imágenes observadas en el microscopio.

Preprocesamiento. Los resultados de la etapa del preprocesamiento se muestran en la figura 4, donde los incisos *a* y *e* muestran las imágenes convertidas a formato Lab, incisos *b* y *f* extracción del canal L, incisos *c* y *g* extracción del canal a y finalmente en los incisos *d* y *h* la extracción del canal b de la muestra 1 y muestra 2 respectivamente).

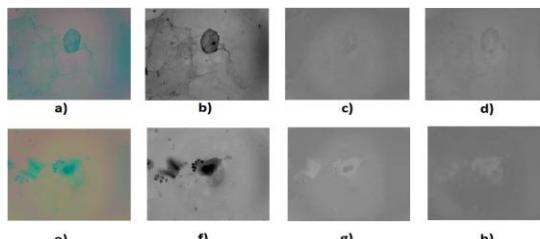


Figura 4. Conversión a formato Lab y extracción de cada uno de sus canales.

Segmentación. Los resultados de la segmentación usando ACO se muestran en la figura 5, donde el inciso *a* corresponde a la muestra 1 y el inciso *b* corresponde a la muestra 2.

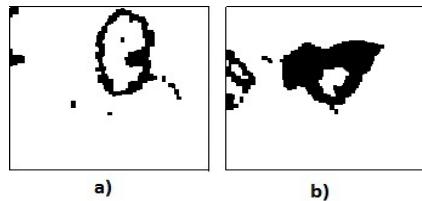


Figura 5. Imágenes segmentadas con ACO.

Extracción de características. En la tabla 2 se muestran las características obtenidas y los resultados de la identificación de color en la muestra 1 se muestran en la figura 6.

Tabla 2. Parámetros calculados en la muestra 1.

Características	Citoplasma	Núcleo
Área	2004	41
Perímetro	218	34
Circularidad	0.530	0.446
Relación núcleo/citoplasma	0.006	0.006

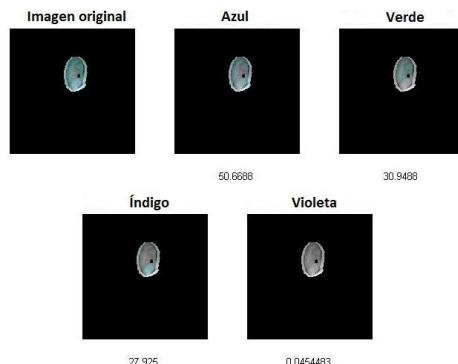


Figura 6. Colores identificados en muestra 1.

También se muestran los resultados de la extracción de características de la muestra 2 que se observan en la tabla 3 y en la figura 7 se muestran los resultados de la identificación de color.

Tabla 3. Parámetros calculados en la muestra

Características	Citoplasma	Núcleo
Área	1751	446
Perímetro	292	106
Circularidad	0.258	0.499
Relación núcleo/citoplasma	0.276	0.276

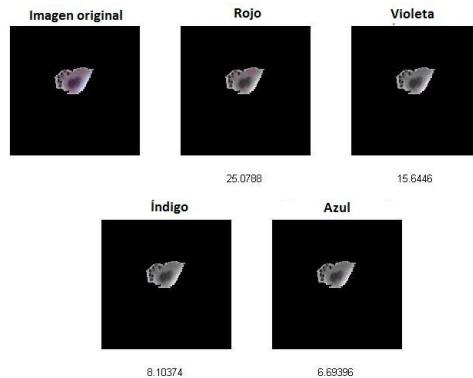


Figura 7. Colores identificados en muestra 2.

Reconocimiento de células e interpretación. Los resultados obtenidos en esta etapa se muestran en la siguiente matriz de confusión (ver tabla 4) donde se puede observar el desempeño de la red al clasificar las imágenes.

Tabla 4. Matriz de confusión del desempeño de la red neuronal de retropropagación.

Muestras	Número de muestras	Cáncer in situ	Carcinoma invasor	Displasias graves	Displasias leves	Displasias moderadas	Otras	%
Cáncer in situ	10	8	1	-	-	-	1	80%
Carcinoma Invasor	5	1	3	-	1	-	-	60%
Displasias Graves	5	1	-	3	-	-	-	80%
Displasias Leves	10	1	-	-	8	-	1	80%
Displasias Moderadas	10	1	-	-	-	9	-	90%
Otras	20	-	1	2	1	1	15	%75

5 Conclusiones y trabajos futuros.

Se logró extraer de manera exitosa cada una de las características más relevantes para realizar la clasificación de nuevas imágenes donde se utilizó la red backpropagation obteniendo una tasa de clasificación del 77.5%, por ello se desea obtener más muestras y probar la efectividad de otros clasificadores tales como SVM y otras redes neuronales hasta obtener niveles mucho más elevados de clasificación para poder garantizar la efectividad y confiabilidad de los resultados.

Referencias

1. Olvera, A.: Citodiagnóstico cervicovaginal. Trillas. 2009.
2. Instituto Mexicano del Seguro Social, cáncer cérvicouterino, <http://www.imss.gob.mx/salud/Cancer/tipos/Pages/cancercervico.aspx>, octubre 2009
3. E. Gallegos: Aplicación de la teoría Wavelets en el análisis de muestras citológicas de Papanicolaou, In Instituto Tecnológico de Apizaco, Apizaco, Tlaxcala, México. 2009.
4. Z. Perez: "Segmentación de células traslapadas en imágenes microscópicas de cérvix con PDI", InInstituto Tecnológico de Apizaco, División de Estudio de Posgrado e Investigación, Maestría en Sistemas Computacionales. Apizaco, Tlaxcala, México. 2011.
5. F. Gallegos, M. Gómez, J. López y R. Cruz: "Rank M-Type Radial Basis Function (RMRBF) Neural Network for Pap Smear Microscopic Image Classification", InApeiron, Vol. 16, No. 4, Octubre 2009.
6. I. Muhammah, R. Kurniawan y Indrayanti: "Automatic Epithelial Cells Detection of Pap smears images using Fuzzy C-Means Clustering", In2012 4th International Conference on Bioinformatics and Biomedical Technology IPCBEE vol. 29 IACSIT Press, Singapore, 2012.
7. L. Mahanta, D. Nath y C. Nath: "Cervix Cancer Diagnosis from Pap Smear Images Using Structure Based Segmentation and Shape Analysis", InJournal of Emerging Trends in Computing and Information Sciences, ISSN 2079-8407, 2012.
8. J. Tian, W. Yu y S. Xie: "An Ant Colony Optimization Algorithm For Image Edge Detection". In IEEExplore, 2008
9. A. Baterina y C. Oppus: "Ant Colony Optimization for Image Edge Detection" In International Journal of Circuits, Systems and Signal processing, pp 25-33. 2010.
10. C. Lacruz y J. Fariña: "Citología ginecológica de Papanicolaou a Bethesda", InEditorial complutense, ISBN 84-7491-717-4.
11. B. Shinde y A. Dani: "Noise Detection and Removal Filtering Techniques in Medical Images", In International Journal of Engineering Techniques in Medical Images, ISSN:2248-9622. Vol. 2, Issue 4,pp. 311-316. July-August 2012.