

Recuperación basada en contenido de imágenes microscópicas de cuello uterino infectadas con el virus del papiloma humano empleando características de textura

Sandra M. Roa Martínez^ψ, Maritza F. Mera Gaona

*Departamento de Sistemas, Facultad de Ingeniería Electrónica y Telecomunicaciones,
Universidad del Cauca, Popayán -Colombia*

Recibido 6 de enero de 2013. Aprobado 1 de noviembre de 2013.

CONTENT-BASED RETRIEVAL OF CERVICAL MICROSCOPIC IMAGES INFECTED WITH HUMAN PAPILLOMAVIRUS USING TEXTURAL FEATURES

RECUPERAÇÃO BASEADA NO CONTEÚDO DE IMAGENS MICROSCÓPICAS DE COLO DO ÚTERO INFECTADO COM VÍRUS DO PAPILOMA HUMANO, UTILIZANDO CARACTERÍSTICAS DE TEXTURA

Resumen — Se presenta el proceso de caracterización implementado para la obtención de descriptores visuales que representan el contenido visual de imágenes digitales de biopsias de cuello uterino infectadas con el Virus del Papiloma Humano (VPH), en las que se capturan tejidos con lesiones conocidas como Condiloma Plano Viral. A partir de la construcción de una base de datos de imágenes de biopsias de cuello uterino y el análisis e implementación de técnicas de filtrado que resaltan la información relacionada a las texturas contenidas en los tejidos que captura cada imagen y de técnicas de extracción de características que describen el contenido de las imágenes; se propone un conjunto de características que describen el contenido de las imágenes a partir de modificaciones propias de la Transformada Discreta de Wavelets y el cálculo de la Matriz de Coocurrencia, donde este conjunto de características propuesto proporcionó un porcentaje promedio de recuperación del 80% en imágenes microscópicas de cuello uterino infectadas con el VPH, sobre las cuales no se conocen sistemas CBIR desarrollados. Finalmente, se determina el porcentaje de recuperación promedio a partir del uso de métricas de similitud basadas en la norma LP.

Palabras Claves — Extracción de características, Recuperación de Imágenes Basada en Contenido (CBIR), Texturas de Tamura, Virus del Papiloma Humano (VPH).

Abstract — The purpose of this work is to report the characterization process implemented to obtain visual descriptors representing visual content of digital images of cervical biopsies infected with Human Papilloma Virus (HPV). Positive biopsies with infected tissues present lesions known as Condyloma Plano Viral. A database of images of cervical biopsies was constructed in addition to the implementation of techniques that enhance the texture information and describe the content of images. This work proposed a set of features to describe the content of images from custom modifications of Discrete Wavelet Transform and

^ψ Dirección para correspondencia: smroa@unicauca.edu.co
DOI: <http://dx.doi.org/10.14508/rbme.2013.7.14.69-80>

the calculation of the Co-occurrence Matrix. This proposed feature set provided an average recovery rate of 80% in microscopic images of the cervix infected with HPV, from which CBIR systems have not been developed. Finally, this work determines the average recovery rate from the use of similarity metrics based on the standard LP.

Keywords — Feature extraction, Content Based Image Retrieval (CBIR), Tamura textures, Human Papilloma Virus (HPV).

Sumário — Neste trabalho é apresentado o processo implementado de caracterização para a obtenção de descrições visuais que representam o conteúdo visual de imagens digitais de biópsias cervicais infectadas com Papilomavírus Humano (HPV), capturadas em lesões de tecidos conhecidas como Condiloma Plano Viral. A partir da construção de uma base de dados de imagens de biópsias do colo uterino, análise e implementação de técnicas de filtragem de características que descrevem o conteúdo das imagens, propõe-se um conjunto de características que descrevem o conteúdo das imagens a partir de modificações próprias da Transformada Discreta de Wavelets e o cálculo da Matriz de co-ocorrência, onde o conjunto de características propostas resultou numa percentagem média de 80% de recuperação nas imagens microscópicas de colo uterino infectado com o VPH, sobre as quais não se percebe o desenvolvimento dos sistemas CBIR. Finalmente, a taxa de recuperação média foi determinada a partir da utilização de métricas de similaridade com base na indicação de LP.

Palavras-chave — Extração de características; Recuperação de imagens baseada em conteúdo (CBIR); texturas Tamura; Vírus do Papiloma Humano (HPV).

I. INTRODUCCIÓN

La Recuperación de Imágenes Basada en Contenido (CBIR-Content-Based Image Retrieval) surge como la solución al problema presentado en los últimos años con la creciente producción de información visual. Actualmente se hace necesario el desarrollo de sistemas CBIR en áreas como la medicina, en donde la producción de imágenes digitales tiene una alta tasa de crecimiento debido a la práctica de diferentes exámenes médicos que originan grandes volúmenes de información visual diariamente [1]. Estos sistemas han surgido como herramientas para la administración y gestión de este tipo de información, así como también para dar soporte a la toma de decisiones clínicas o al entrenamiento de nuevos profesionales de la salud en el área específica a la que correspondan las imágenes que permite recuperar el sistema, se ofrece como resultado en una consulta las imágenes visualmente similares y sus respectivos diagnósticos, los cuales han sido validados por expertos en el tema, dando esto soporte para la ayuda en la generación del nuevo diagnóstico de la imagen de estudio [2].

Los esfuerzos en el desarrollo de sistemas CBIR se centran principalmente en la selección de las características que describen el contenido de las imágenes digitales con las cuales se puede comparar y evaluar el grado de similaridad presente entre un par de imágenes.

La textura en una imagen puede ser percibida como el cambio de los niveles de intensidad en una región. Sin embargo, el gran desafío es encontrar las medidas que permitan representar ese cambio de intensidad en las imágenes.

Para la colección de imágenes microscópicas de cuello uterino seleccionada, en su caracterización visual es

relevante tener en cuenta que la información capturada en cada una de estas imágenes contiene tejidos infectados por el Virus del Papiloma Humano (VPH). En estas imágenes el análisis de texturas representa el análisis de las estructuras celulares de los tejidos que permite identificar patrones con los cuales se determina la presencia o ausencia de la patología.

El VPH es la infección de transmisión sexual de mayor frecuencia [3]. El VPH incluye una familia de más de 200 papilomavirus identificados, de los cuales algunos son considerados de bajo riesgo y producen lesiones como las verrugas genitales que pueden ser detectadas por los pacientes, mientras que los considerados de alto riesgo producen alteraciones premalignas a nivel vaginal o del cuello uterino que pueden evolucionar a cáncer [3, 4]. Estas lesiones no son visibles y solo son detectadas a través de exámenes practicados por especialistas.

El cáncer de cuello uterino es una de las principales causas de muerte en mujeres en países en vía de desarrollo y es considerado como uno de los primeros problemas de salud pública a nivel mundial por las altas cifras de incidencia según el reporte del Ministerio de Salud en el año 2008. Asimismo según diarios del orden nacional como el Espectador en Colombia, durante el 2012 se estimó que cada día morían 9 mujeres a causa del cáncer de cuello uterino y a nivel mundial aproximadamente 270 mil cada año. Uno de los aspectos que garantizan el éxito del tratamiento sobre esta patología es la identificación de la misma en un estado temprano. Es por eso la relevancia de la detección de las lesiones precursoras de displasias que favorecen el desarrollo del cáncer, estas lesiones son conocidas como Condiloma Plano Viral y son producidas por la presencia del VPH [4, 5].

Por otra parte, en la implementación de algunos sistemas CBIR se usan bases de datos de imágenes médicas alimentadas a partir de tomografías computarizadas, radiografías, resonancias, ecografías y análisis histopatológicos, entre otros. Para la extracción de características asociados a la representación de textura, se usan las transformadas de imágenes, el cálculo de la matriz de coocurrencia, las características de tamura y el filtrado espacial de imágenes con el objetivo de identificar y resaltar información que permita discriminar las texturas. En trabajos como el de Howarth [6] se emplearon las transformadas discretas del coseno, Wavelet y Fourier junto al cálculo de histogramas, el cálculo de la matriz de coocurrencia y las características de Tamura para construir la representación visual de un conjunto de imágenes de tomografías, resonancias y radiografías. Asimismo otras publicaciones han usado las características de tamura y el cálculo de la matriz de coocurrencia para la representación de texturas.

Para caracterizar las imágenes digitales de cuello uterino presentes en la base de datos se usó el cálculo de las texturas de tamura, los filtros de Sobel, Roberts y Laplace, estos últimos para resaltar la información relacionada a las texturas sobre la imagen a caracterizar. A partir de las seis imágenes resultantes se realiza la extracción de características a través de adaptaciones de la transformada discreta de Wavelets y el cálculo de la matriz de coocurrencia.

En este trabajo se presenta en la siguiente sección los materiales y métodos utilizados, posteriormente los

resultados y el análisis de los mismos y finalmente las conclusiones obtenidas en el proyecto realizado.

II. MATERIALES Y MÉTODOS

2.1. Base de datos de imágenes

Las imágenes microscópicas almacenadas en la base de datos son obtenidas a partir de la digitalización de biopsias de cuello uterino en las que se analizan las alteraciones sufridas en el epitelio a causa de la presencia del VPH. Morfológicamente la infección se manifiesta sobre el tejido a través de alteraciones conocidas como criterios de Toki; cada criterio o alteración está asociada a un peso como se muestra en la Tabla 1. Cuando en un estudio histopatológico de una biopsia se encuentra que la sumatoria de los pesos de todas las alteraciones identificadas presenta más de 6 puntos, se diagnostica presencia de VPH.

Tabla 1. Criterios de Toki

Criterio	Puntaje
Coilocitos	4
Bi o multinucleación	2
Disqueratosis	1
Papilomatosis	1
Hiperplasia de las células basales	1
Acantosis	1



Fig. 1. Imagen de placas originales de biopsias.

La base de datos de imágenes digitales se realizó con la digitalización de un conjunto de 30 biopsias de cuello uterino de tejidos infectados con el VPH que presentaban alteraciones de Condiloma Plano Viral. Estas se usaron junto con biopsias de cuello uterino que no presentaban alteraciones en los tejidos contenidos en las placas. Las biopsias digitalizadas en la construcción de la base de datos empleada en este proyecto pertenecen al laboratorio de la compañía de patólogos del Cauca. Los casos que presentaban infección de VPH fueron seleccionados a partir de los históricos clínicos del laboratorio que reportaron positivo en esta infección, mientras los casos de biopsias que no presentaban ningún tipo de infección incluidas en la base de datos fueron brindados directamente por los patólogos. En la Fig. 1 se muestra un ejemplo de las placas originales de las biopsias.

De cada placa obtenida a partir de una biopsia en donde se plasman cortes del tejido de cuello uterino, se tomaron varias imágenes digitales que representaron diferentes cortes de la placa o diferentes regiones de un corte. La digitalización de las imágenes se realizó a través de un microscopio Nikon Eclipse 80i, equipado con una cámara digital con la que se capturaron las imágenes digitales de las placas con una resolución de 40x. Durante la digitalización de todas las placas seleccionadas se empleó una configuración diferente del microscopio en cada caso debido a que las placas no presentaban condiciones iniciales estándar. En la configuración del microscopio para cada caso se tuvo como criterio: identificar las texturas de las estructuras celulares de los tejidos, en algunos casos se aumentó la cantidad de luz aplicada sobre la placa y en otros casos en los que la placa presentaba una coloración mínima se redujo la intensidad de la luz aplicada. En general, los ajustes de acercamiento y cantidad de luz aplicada durante la configuración del microscopio para la digitalización de cada biopsia se realizaron con el objetivo de identificar visualmente las texturas de los tejidos.

En la captura realizada sobre cada biopsia se pueden obtener varias imágenes, donde cada imagen puede contener una amplia región del tejido. Sin embargo, el análisis que realizan los especialistas no tiene en cuenta la imagen completa, dado que el estudio es enfocado sobre las células ubicadas en la zona media o superior del tejido epitelial mostrado, donde las células encontradas en la base del tejido no han alcanzado el proceso de diferenciación suficiente para lograr distinguir una célula con respecto a otra. En la Fig. 2 se muestra la región de la imagen sobre la cual se pueden elegir subregiones correctas para realizar el análisis. Así mismo, se muestra una región de la imagen perteneciente a la base del tejido epitelial en donde no se recomienda escoger una subregión

porque se encuentran células alargadas, superpuestas y otros detalles que son asociados a la diferenciación de las células en esa región.



Fig. 2. Imagen de biopsia de cuello uterino y regiones de análisis en el diagnóstico.

A partir de las imágenes digitalizadas directamente de las placas de biopsias de cuello uterino se realizaron cortes de regiones de interés que fueron almacenadas y caracterizadas en la base de datos. En cuanto a las condiciones de digitalización y ajuste de las regiones almacenadas en la base de datos es importante mencionar que las regiones tienen dimensiones diferentes y durante el proceso de digitalización se emplearon diferentes configuraciones en el microscopio. Finalmente, el conjunto de imágenes definido para probar la recuperación del prototipo se construyó seleccionando en total 12 regiones de prueba.

2.2 Caracterización de las imágenes

La caracterización de una imagen es el proceso en el que se construye el vector de características que representa su contenido. En este estudio las imágenes de la base de datos fueron procesadas digitalmente para resaltar información relevante en la discriminación de texturas según el sistema de visión humano. Para esto se implementaron algoritmos de filtrado, con el fin de obtener de cada imagen de la base de datos seis nuevas imágenes y sobre éstas aplicar los extractores de características, como se muestra en la Fig. 3.

2.2.1 Texturas de Tamura

Estas definen 6 propiedades que influyen la forma en que la visión humana diferencia o reconoce texturas. Tamura diseña sus características como la medida de cada uno de estos aspectos y según su experimento coarseness, contraste y direccionalidad son las características que presentan un mejor comportamiento en la descripción

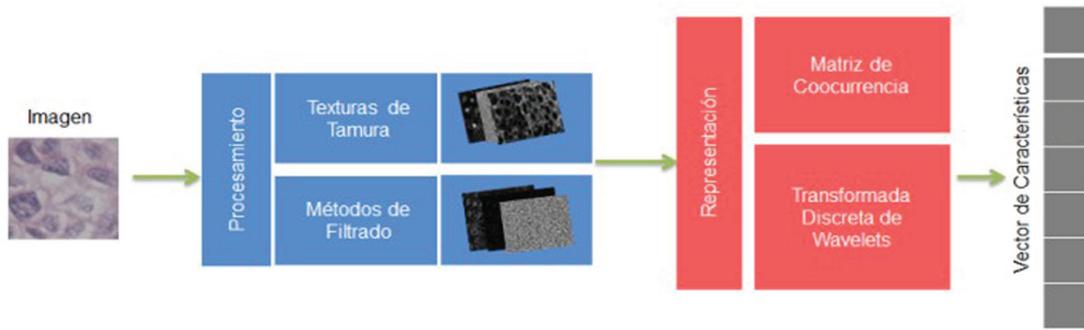


Fig. 3. Caracterización de una imagen digital.

de texturas, ya que son los que presentan un mayor nivel de relación con la percepción humana [6, 9-11]. En anteriores proyectos se han empleado las tres imágenes generadas a partir del cálculo de las características de Tamura: coarseness, contraste y direccionalidad, para la construcción de una nueva imagen con información en los tres canales del sistema RGB. Esta imagen es conocida como la imagen de Tamura y es fuente de información para generar un histograma de niveles de grises, en el que se describe información relacionada a la variación de los niveles de gris presentes en una textura. Sin embargo, en este proyecto el cálculo de coarseness, contraste y direccionalidad fue empleado como técnicas de filtrado para resaltar información relacionada a la discriminación de texturas que realiza el sistema de visión humano. Los algoritmos fueron implementados y probados con diferentes parámetros de calibración, de tal manera que el cálculo hecho sobre las imágenes digitales de cuello uterino logra una descripción particularizada de las texturas presentes en este tipo de imágenes y al mismo una reducción de la complejidad computacional en la ejecución de los algoritmos.

A continuación se describen brevemente las tres características mencionadas:

2.2.1.1 Coarseness

El objetivo de medir Coarseness en las imágenes digitales de cuello uterino es capturar información relacionada al tamaño de las texturas presentes en la biopsia [9].

El algoritmo que describe el cálculo de coarseness se describe a continuación:

```

para i= 0 hasta numerodefilas (I)
    para j= 0 hasta numerodecolumnas (I)
        I(i,j)=PromedioVecindad(I,i,j)
    fin_para
fin_para
    
```

```

para i=0 hasta numerodefilas (I)
    para j=0 hasta numero columnas (I)
        I1(i,j) = DiferenciasOpuestosNo-
                solapadosVertical (I,i,j)
        I2(i,j) = DiferenciasOpuestosNo-
                solapadosHorizontal
                (I,i,j)
    fin_para
fin_para
para i=0 hasta numerodefilas (I)
    para j=0 hasta numerodecolumnas (I)
        I(i,j)=AsignarMayorDiferencia
        (I1 (i,j),I2(i,j))
    fin_para
fin_para
Normalizar (I)
    
```

2.2.1.2 Contraste

Se evaluaron diferentes tamaños de vecindades y se encontró que a medida que las vecindades aumentan su tamaño no solo se incrementa la complejidad computacional sino que se identifican patrones de texturas más grandes.

El contraste (Fcon) medido en cada pixel de una imagen se define como:

$$Fcon = \frac{\sigma}{(\alpha_4)^n} \quad \text{con} \quad \alpha_4 = \frac{\mu_4}{\sigma^4} \quad \text{y} \quad \mu_4 = \sum_{i,j=1}^{n,n} \frac{(I(i,j)-\mu)^4}{n \times n}$$

En donde μ_4 es calculada sobre una vecindad en cada pixel y representa el cuarto momento alrededor de la media μ de la intensidad de la imagen completa (Howarth & Ruger, 2005). El algoritmo que describe el cálculo del contraste es el siguiente:

```

para i = 0 hasta numerodefilas (I)
  para j = 0 hasta numerodecolumnas (I)
     $\mu_4 = \text{calcular4tomomento}(\text{vecindad}(\text{I}(i,j),k))$ 
     $\alpha_4 = \mu_4/\text{varianza}^2$ 
     $\text{I}(i,j) = \text{Fcon} = \text{raizcuadrada}(\text{varianza}) / (\alpha_4)^{1/4}$ 
  fin_para
fin_para
Normalizar (I)

```

2.2.1.3 Direccionalidad

Este es un aspecto importante en las texturas, es considerada como una propiedad global sobre una región de la imagen. En este método no se define como tal la orientación sino que su objetivo es identificar la presencia de la dirección en la imagen [6, 11].

El algoritmo que describe el cálculo de la direccionalidad es el siguiente:

```

para i=0 hasta numerodefilas (I)
  para j=0 hasta numerodecolumnas (I)
     $\text{ah} = \text{derivadaH}(\text{I}(i,j))$ 
     $\text{av} = \text{derivadaV}(\text{I}(i,j))$ 
     $\text{I}(i,j) = (3.1416/2) + \text{atan}(\text{av}/\text{ah})$ 
  fin_para
fin_para
Normalizar (I)

```

2.2.2 Dominio Espacial de Filtrado

En general es un método muy sencillo de procesamiento de señales que permite obtener información acerca de las texturas con relación a los bordes que se puedan identificar en la imagen a través de máscaras. Para la detección de los bordes pueden usarse, por ejemplo, los operadores de Sobel, Roberts o Laplacianos. En este estudio los métodos de filtrado espacial implementados resaltan la información relacionada a los bordes y eliminan el ruido contenido en la imagen. Esto tiene por objetivo identificar estructuras celulares y patrones morfológicos que son considerados como relevantes en el diagnóstico de imágenes digitales de biopsias de cuello uterino.

A continuación se presentan los filtros seleccionados para aplicar sobre las imágenes de la base de datos.

2.2.2.1 Filtro de Sobel.

Se resaltan los bordes de los detalles celulares más importantes del contenido de la imagen. El algoritmo que describe el filtro de Sobel es el siguiente:

```

para i = 0 hasta numerodefilas (I)
  para j=0 hasta numerodecolumnas (I)
     $\text{ah} = \text{derivadaH}(\text{I}(i,j))$ 
     $\text{av} = \text{derivadaV}(\text{I}(i,j))$ 
     $\text{I}(i,j) = \text{raizCuadrada}(\text{ah}^2 + \text{av}^2)$ 
  fin_para
fin_para

```

2.2.2.2 Filtro de Laplace

Se resaltan los bordes de todas las estructuras celulares de la imagen. El algoritmo que describe el filtro de Laplace es el siguiente:

```

para i = 0 hasta numerodefilas (I)
  para j = 0 hasta numerodecolumnas (I)
     $\text{I}(i,j) = \text{convolucionLaplace}(\text{I}(i,j))$ 
  fin_para
fin_para

```

2.2.2.3 Filtro de Roberts

Se identifican los bordes relacionados a los detalles relevantes de la estructura celular que se analiza, se resaltan principalmente los bordes asociados a los núcleos de las células y eliminan los bordes relacionados a estructuras pertenecientes a regiones homogéneas más pequeñas. El valor de cada pixel de la imagen se calcula de la siguiente manera:

$$\text{DIR}(\text{I}(x,y)) = |f(x,y) - f(x+1,y+1)| + |f(x,y+1) - f(x+1,y)|$$

El algoritmo que describe el filtro de Roberts es el siguiente:

```

para i = 0 hasta numerodefilas (I)
  para j=0 hasta numerodecolumnas (I)
     $\text{I}(i,j) = \text{DIR}(\text{I}(x,y))$ 
  fin_para
fin_para
Normalizar (I)

```

2.2.3 Extracción de Características

Los extractores de características implementados se describen a continuación y son aplicados sobre cada una de las seis imágenes resultantes del procesamiento con los algoritmos de tamura y filtrado espacial.

2.2.3.1 Matrices de Coocurrencia

A diferencia del cálculo de la matriz de coocurrencia tradicional [12], en este trabajo se implementó el cálculo de una matriz de coocurrencia con frecuencias invariantes que considera las 4 principales orientaciones 0°, 45°,

90° y 135°. En una misma matriz se almacenaron todas las frecuencias de color encontradas en las diferentes orientaciones. Adicionalmente, el tamaño de la matriz de coocurrencia está directamente relacionado con el número de niveles de gris soportados en la imagen, por esta razón, si el número de niveles de gris es de 256 entonces el tamaño de la matriz de coocurrencia es de 256x256, resultando computacionalmente de alto costo. La solución implementada reduce el tamaño de la matriz considerando grupos de valores niveles de gris en lugar de valores por separado, por ejemplo, se define el tamaño de la nueva matriz de coocurrencia de 8x8, lo que indica que los 256 niveles de gris existentes se reducen a 8, y se organizan grupos de niveles de gris de 32 (256/8) para determinar la frecuencia de color en la nueva matriz de coocurrencia, los niveles de gris se agrupan de la siguiente manera [0,31], [32,63],..., [224,255] según la referencia [13].

2.2.3.2 Transformada Discreta de Wavelets

Este método consiste en descomponer la imagen utilizando alguna de las diferentes funciones de Wavelets para obtener la representación de la imagen a partir de la media y la varianza de la distribución de energía de cada coeficiente de la transformada. Los coeficientes representan aproximaciones, detalles horizontales, detalles verticales y detalles horizontales de la imagen original [14].

Adicional a la media y la varianza que describen el contenido de la imagen se tuvieron en cuenta las *co-occurrence signature de Wavelets* [14] que resultan a partir del cálculo de la matriz de coocurrencia que se obtiene sobre cada uno de los coeficientes horizontales, verticales y diagonales que se producen al aplicar las wavelets en cada uno de los niveles de descomposición sobre una imagen.

2.3 Medidas de similaridad

Las funciones de similaridad implementadas para evaluar la similitud de las imágenes están basadas en la Distancia Minkowski o norma LP [16], a partir de esta se han considerado y modificado los casos particulares: Distancia Manhattan, Distancia Euclidiana y Distancia Chebyshev.

La norma Lp se define como:

$$D_{Norma-Lp}(x,y) = \left[\sum_{i=1}^M (x_i - y_i)^p \right]^{1/p}$$

Cuando p=1:

$$D_{Manhattan} = \sum_{i=1}^M |x_i - y_i|$$

Cuando p= 2:

$$D_{Euclidiana} = \left[\sum_{i=1}^M (x_i - y_i)^2 \right]^{1/2}$$

Cuando p= ∞:

$$D_{Chebyshev} = D_{\infty} = \max_{1 \leq i \leq M} |x_i - y_i|$$

Para determinar la medida de similaridad que emplea la recuperación basada en contenido implementada se aplicó una normalización sobre los valores de las características de las imágenes almacenadas en la base de datos. Los valores fueron transformados empleando una distribución normal para convertir los valores de las características en valores dentro de un rango de 0 a 1. Lo anterior se realizó con el objetivo de darle la misma relevancia a todas las características almacenadas de una imagen, ya que si no se realizaba este proceso de normalización algunas características cuyos valores no eran mayores que 1 estarían en desventaja frente a características cuyos valores oscilaran por encima de 100.

El resultado de aplicar una función de similaridad entre dos imágenes digitales y obtener un valor cercano a 0 indica que la imagen tiene un alto grado de similaridad mientras que un valor cercano a 1 indica que las imágenes son totalmente diferentes. Según lo anterior, las medidas de similaridad al evaluarse deben ofrecer un valor entre 0 y 1, y considerando que debido a la normalización realizada sobre las características, en donde también los datos se encuentran entre 0 y 1, fue necesario modificar las medidas de distancia y en la implementaciones aplicar las fórmulas que describen su funcionamiento y el resultado obtenido dividirlo por el mayor valor que esta función podría presentar. Debido a que si tenemos un conjunto de 100 características y se comparan dos imágenes digitales cuyas características las describen como imágenes sin ningún grado de similaridad, es decir, los valores de las características de una imagen estén definidas como 1 ó 0 y los valores de las características de la otra imagen sean opuestos a este valor, tendríamos lo siguiente para las tres medidas de distancia:

$$D_{Manhattan} = \sum_{i=1}^{100} |1 - 0| = 100 > 1$$

$$D_{Euclidiana} = \left[\sum_{i=1}^{100} (1 - 0)^2 \right]^{1/2} = 10 \cdot 10 > 1$$

$$D_{Chebyshev} = \max_{1 \leq i \leq 100} |1 - 0| = 1$$

Por lo anterior, las distancias Euclideana y Manhattan implementadas fueron las siguientes: Chevyshev no fue modificada debido a que no era necesario:

$$D_{Manhattan} = \frac{\sum_{i=1}^M |x_i - y_i|}{M}$$

$$D_{Euclidiana} = \left[\frac{\sum_{i=1}^M (x_i - y_i)^2}{M} \right]^{1/2}$$

Donde X y Y son imágenes, x_i corresponde a la i-ésima característica de la imagen X, y_i a la i-ésima característica de la imagen Y, y M el número total de características de X y Y.

III. RESULTADOS Y DISCUSIÓN

A partir de un conjunto definido de imágenes se realizaron las pruebas del desempeño de la recuperación implementada. Se seleccionaron 12 regiones de prueba para las cuales se conocía a priori la respuesta que debe brindar la recuperación para un desempeño del 100%; cada

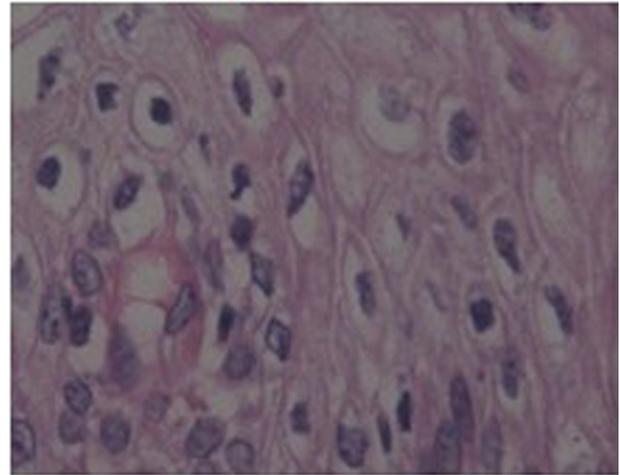


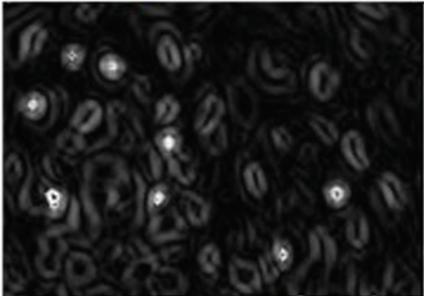
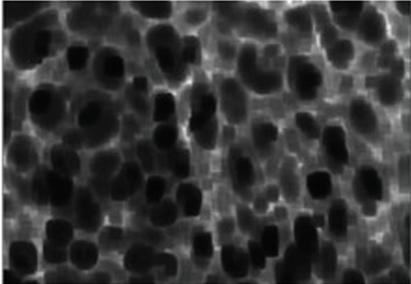
Fig. 4. Imagen de biopsia de cuello uterino original.

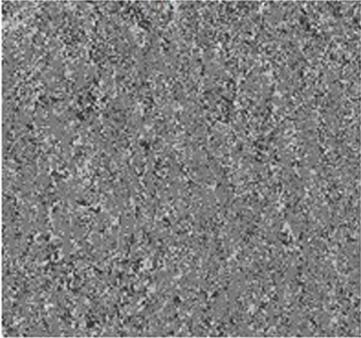
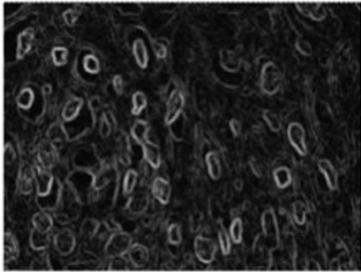
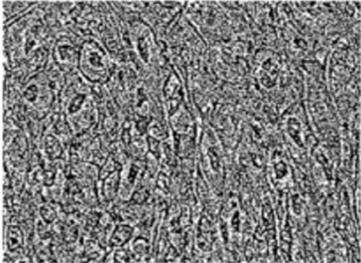
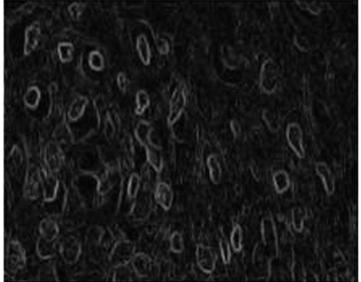
región de prueba contiene en la base de datos 5 imágenes consideradas con un alto grado de similitud.

Inicialmente a las imágenes seleccionadas se aplicaron las técnicas de caracterización mencionadas en la sección anterior a partir de la imagen original de la Fig.4.

Un resumen de los resultados obtenidos se pueden observar en la tabla 2:

Tabla 2. Imágenes obtenidas a partir de la aplicación de técnicas de caracterización.

Detalle de la técnica	Resultado de imagen obtenida
<p>Coarseness</p> <p>Se encontró que las vecindades de tamaño 2^1 y 2^2 empleadas en el algoritmo se comportaban de mejor forma en la identificación de los patrones de textura presentes en las imágenes de evaluación que se probaron. Esto resultó ventajoso además porque computacionalmente incrementar el tamaño de la vecindad significa aumentar la complejidad computacional del algoritmo y así mismo los tiempos de respuesta.</p>	
<p>Contraste</p> <p>Se puedan identificar como patrones de textura a nivel del núcleo y el citoplasma de una célula o por el contrario que la célula completa sea considerada como una región homogénea en donde se destaca un macro patrón de textura.</p>	

<p>Direccionalidad</p> <p>En los análisis histopatológicos que realizan los patólogos sobre las imágenes digitales de los tejidos de cuello uterino, la direccionalidad identificada permite describir patrones morfológicos que son claves para el diagnóstico de éste tipo de imágenes.</p>	
<p>Filtro de Sobel</p> <p>Se resaltan los bordes de los detalles celulares más importantes del contenido de la imagen, especialmente los relacionados a los núcleos de las células.</p>	
<p>Filtro de Laplace</p> <p>En esta imagen se resaltan los bordes de todas las estructuras celulares de la imagen. Sin embargo, los bordes que se pueden observar con mayor claridad corresponden a los asociados con las membranas y núcleos de las células.</p>	
<p>Filtro de Roberts</p> <p>Al comparar esta imagen con el resultado obtenido en la imagen filtrada de Sobel, se encuentra básicamente la misma información. Por esto se recomienda, en futuros proyectos, analizar el comportamiento de los descriptores extraídos de este par de imágenes para evitar redundar en la información con la que se caracteriza la imagen original.</p>	

Posteriormente, fue construido un prototipo software como buscador web, el cual soporta la búsqueda basada en contenido visual sobre la base de datos de imágenes digitales de cuello uterino, y su objetivo es la formulación de las consultas por contenido sobre la base de datos construida con las 12 regiones seleccionadas de las imágenes digitales de biopsias de cuello uterino con lesiones causadas por el VPH; en cada una de las consultas mencionadas fue considerada una región de prueba y el retorno de cinco imágenes con el mayor grado de similitud con respecto a la región de prueba, donde los

resultados obtenidos fueron comparados con los resultados esperados. Realizando el procedimiento anterior se genera una matriz de confusión (ver Tabla 3) que permite obtener la precisión de la recuperación para cada una de las imágenes de prueba y la precisión total de la recuperación según los 12 casos de prueba. De las tres medidas de similitud (distancia) la que mostró mejor desempeño fue la distancia de Manhattan modificada con un 80% de porcentaje de acierto. Los resultados obtenidos empleando esta medida fueron agrupados en la Tabla 4.

Adicionalmente, en la matriz de confusión construida se representa la información de los falsos positivos recuperados y falsos negativos no recuperados dentro de las 5 primeras imágenes recuperadas en cada consulta. Teniendo en cuenta que el rendimiento ideal de un sistema de búsqueda es aquel en el que la precisión y recall (exhaustividad) son altos (cerca de 1) en la tabla 4 se muestran los valores de la recuperación para estas dos medidas de desempeño según la evaluación realizada. Considerando que para la evaluación realizada para cada consulta el número de imágenes recuperadas es igual al

número de imágenes relevantes, tenemos una precisión y exhaustividad promedio de 0.8.

Los 12 casos de imágenes junto al conjunto de imágenes que conforman la respuesta ideal fueron seleccionados por un patólogo experto en el diagnóstico de este tipo de imágenes.

Precisión=imágs. relevantes recuperadas/imágenes recuperadas.

Recall=imágs. relevantes recuperadas/imágenes relevantes.

Tabla 3. Matriz de Confusión.

Clase	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	Porcentaje
C1	4	1											80%
C2		2								1		2	40%
C3			4						1				80%
C4				4	1								80%
C5					5								100%
C6						5							100%
C7						1	4						80%
C8								4		1			80%
C9									5				100%
C10										4	1		80%
C11										2	3		60%
C12										1		4	80%
Porcentaje de precisión de recuperación													80%

Tabla 4. Resultados de la evaluación.

Imagen de Prueba	Umbral	Aciertos	Errores	%	Precisión	Recall	
1	78,40	4	1	80,00	4/5	4/5	
2	76,77	2	3	40,00	2/5	2/5	
3	74,97	4	1	80,00	4/5	4/5	
4	76,92	4	1	80,00	4/5	4/5	
5	78,62	5	0	100,00	5/5	5/5	
6	82,01	5	0	100,00	5/5	5/5	
7	78,01	4	0	80,00	4/5	4/5	
8	77,24	4	1	80,00	4/5	4/5	
9	79,65	5	0	100,00	4/5	4/5	
10	80,86	4	1	80,00	4/5	4/5	
11	81,47	3	2	60,00	3/5	3/5	
12	79,15		1	80,00	4/5	4/5	
				Promedio	80,00	0.8	0.8

A partir de la evaluación realizada se concluye que el porcentaje promedio de acierto de la recuperación del prototipo es de un 80%. Si bien, es importante tener en cuenta que en el caso de la región de prueba número 2 el desempeño de la recuperación fue solo un 40% afectando negativamente el promedio de recuperación. Este bajo desempeño se pudo presentar, posiblemente, debido a que los núcleos y la estructura celular en general de las células contenidas en la región de prueba y el conjunto regiones de respuesta ideal no se encontraban bien definidas, dificultando el análisis de las texturas. La Fig. 5 muestra la imagen de prueba número 2 y una de sus regiones similares.

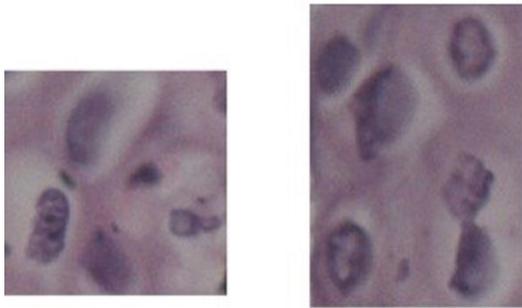


Fig. 5. Imagen de prueba 2 junto a una imagen similar.

En las pruebas realizadas con las regiones de prueba 1 y 12 se pudo observar que dentro de los primeros 5 resultados proporcionados por el prototipo, 4 de ellos pertenecían al conjunto de respuesta deseada y la quinta imagen perteneciente a ese mismo conjunto se ubicaba como el resultado número 6 de la respuesta proporcionada por la recuperación. Adicionalmente, se pudo observar que la imagen brindada por la recuperación en su respuesta y que no pertenecía al conjunto de la respuesta esperada, visualmente también presentaba algunos rasgos en las estructuras celulares que aprueban patológicamente la presencia de ésta en la respuesta. Una situación similar se presenta para el caso de prueba número 11, ver Fig. 6, donde se muestra la región de prueba número 11, junto a una imagen que inicialmente fue considerada como mal recuperada por no pertenecer al conjunto de imágenes de la respuesta ideal.

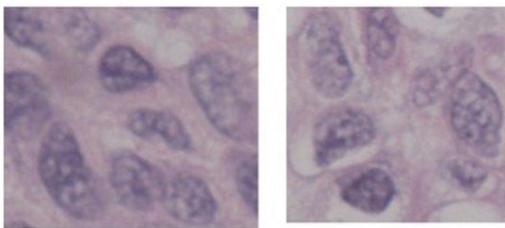


Fig. 5. Imagen de prueba 2 junto a una imagen similar.

Finalmente, la evaluación realizada permitió establecer que según las respuestas brindadas en la recuperación basada en contenido para los 12 casos de prueba evaluados, el umbral mínimo de similaridad definido a partir de las similaridades encontradas en los primeros 5 resultados de las 12 consultas realizadas es aproximadamente del 75%, teniendo así que la recuperación implementada es de un 80% y el rango de similaridad encontrado en la evaluación para dicho porcentaje es superior a un 75%.

En los antecedentes revisados en el desarrollo de este proyecto en donde se evalúa la capacidad de discriminación de características extraídas de imágenes digitales se encontró que en [1] se encuentran porcentajes de desempeño desde el 60% hasta aproximadamente 80%. En [17] se encuentran desempeños superiores al 71% para los diferentes extractores de características empleados. En [18] se obtienen porcentajes de desempeño que oscilan entre 70% y 85% para las algunas de las evaluaciones realizadas. En [19] se encuentra un desempeño aproximado al 70%. Al comparar los resultados de este proyecto con estas referencias en la literatura, se puede concluir que el desempeño ofrecido por el prototipo construido es aceptable comparándolo con algunos antecedentes nacionales e internacionales. Particularmente en [1] y [17] los sistemas desarrollados al igual que en este estudio trabajan sobre ambientes clínicos, sin embargo, las imágenes de las bases de datos son de diferentes orígenes, los porcentajes de desempeño de estos sistemas son utilizados como referencia para evaluar el desempeño esperado de un sistema de recuperación de imágenes médicas basada en contenido. Por otro lado, el desempeño de la recuperación por contenido representa para los patólogos un valor de confiabilidad respecto a que los primeros resultados arrojados en una consulta son realmente las imágenes de la base de datos que tienen un mayor grado de similaridad con la imagen de consulta. El grado de similaridad se describe a través de un porcentaje que permite ordenar los resultados en orden descendente (de la imagen más similar a la menos similar), de tal manera que en los resultados de una consulta el patólogo podrá recorrer toda la colección bajo este principio.

IV. CONCLUSIÓN

Se obtuvo un conjunto de propiedades visuales capaces de discriminar las texturas presentes en las imágenes digitales de biopsias de cuello uterino. Esto se logró a partir del cálculo de la matriz de Coocurrencia sobre las imágenes generadas de las mismas (imágenes filtradas y texturas de Tamura) y sobre los coeficientes de la transformada discreta de Wavelets calculados.

La evaluación realizada al prototipo demostró que las técnicas de extracción de características implementadas son independientes del tamaño de las imágenes, de las condiciones iniciales de las placas de las biopsias de Cuello Uterino y de las configuraciones del microscopio óptico empleado para la captura de las imágenes.

Las modificaciones y ajustes realizados a los algoritmos de filtrado, extracción de características y métricas de similitud, permitieron la recuperación de imágenes digitales de biopsias de cuello uterino con tejidos infectados con VPH y diferenciarlos entre ellos. Para esto se consideró que todas las imágenes de la base de datos contenían tejidos que presentaban alguna o algunas de las alteraciones definidas por los criterios de Toki que determinan la ausencia o presencia de VPH.

En las pruebas realizadas, la distancia de Manhattan resultó ser la función de similaridad con mejor desempeño, comparado además con otras medidas evaluadas como la Distancia Euclidiana y Distancia de Chebyshev.

En el proceso de digitalización de las imágenes de biopsias de cuello uterino se definió que es importante garantizar que la imagen digital que se capture debe contener las estructuras celulares bien definidas, de tal manera que se puedan diferenciar las texturas de los núcleos y sus membranas. De lo contrario el desempeño del prototipo se puede ver afectado negativamente.

La caracterización implementada para las imágenes digitales de biopsias de cuello uterino permite describir visualmente tejidos infectados con VPH y diferenciarlos entre ellos, debido a que según los criterios de Toki son diferentes alteraciones las que se pueden presentar en el tejido.

AGRADECIMIENTOS

Los autores agradecen al Grupo de Investigación en Tecnologías de la Información (GTI) y Grupo de Inteligencia Computacional (GICO) adscritos al Departamento de Sistemas de la Universidad del Cauca, a la Compañía de Patólogos del Cauca, al Laboratorio de Microscopía de la Universidad del Cauca y al MD. Harold Bolaños.

REFERENCIAS

- [1]. Caicedo, J. C., González, F., Romero, E., Sánchez, Y. Evaluación de Características de Bajo Nivel para Recuperación de Imágenes de Histología por Contenido. *Congreso Colombiano de Computación - CCC 2007*.
- [2]. Müller, H. Comparing features sets for content-based image retrieval in a medical-case database. *Medical Imaging*, 2004.
- [3]. Dailard, C. HPV in the United States and Developing Nations: A Problem of Public Health or Politics?. *The Guttmacher Report on Public Policy*, Agosto 2003, 6(3). Disponible en: <http://www.guttmacher.org/pubs/tgr/06/3/gr060304.html>
- [4]. Pérez-López, F. Virus del papiloma, condilomas verrugosos, CIN, SIL y cáncer genital. España. Facultad de Medicina, Universidad de Zaragoza. Disponible en: <http://www.unizar.es/gine/gin301.htm>
- [5]. Navarro T, S., Campusano, M., Mendoza I., Pereira R., Polo F., Ríos E., Olivares J., Bernal, M. Cáncer de cervix y su relación con el virus del papiloma humano. *Ciencia y Salud*, 3(1) 160-168. 2011.
- [6]. Howarth, P. Discovering images: features, similarities and subspaces. *Ph.D. thesis, University of London, Department of Computing*.
- [7]. Pi M. H., Tong, C. S., Choy, S. K., Zhang, H. A Fast and Effective Model for Wavelet Subband Histograms and Its Application in Texture Image Retrieval. *IEEE Transactions on Image Processing*, 2006.
- [8]. Busch, A. Wavelet Transform for Texture Analysis With Application to Document Analysis. *Ph.D. Thesis, Queensland University of Technology*, 2004.
- [9]. Howarth, P., Ruger, S. Robust texture features for still-image retrieval. Recent advances in image and video retrieval. *IEEE Proceedings Vision, Image & Signal Processing*, 152(6), pp. 868-874.
- [10]. Tamura, S. M., Yamawaki, T. Textural features corresponding to visual perception. *Transactions on Systems, Man and Cybernetics*, 446-455, 1978.
- [11]. Caicedo Rueda, J. C. Extracción de Características para Recuperación de Imágenes por Contenido, Universidad Nacional de Colombia, 2008.
- [12]. Presutti, M. La matriz de co-ocurrencia en la clasificación multispectral: tutorial para la enseñanza de medidas texturales en cursos de grado universitario. *4ª Jornada de Educação em Sensoriamento Remoto no âmbito do Mercosul*, 2004.
- [13]. Mery, D. Extracción de Características. Tesis, Departamento de las ciencias de la computación de la Universidad de Chile, 2006.
- [14]. Li L., Tong C.S., Choy S.K. Texture classification using refined histogram. *IEEE Trans. Image Process.* 19(5), 1371-1378, 2008.
- [15]. Henao, A. Compresión de imágenes usando la transformada de wavelet y el algoritmo de Huffman, Universidad de Manizales, 2004.
- [16]. Acuna, E. Unsupervised classification, Clustering. Notas de Clase. Mayaguez, Universidad de Puerto Rico. University of Puerto Rico, 2002.
- [17]. Lehmann, T. M., Guld M.O., Deselaers T., Keysers D., Schubert H., Spitzer K., Nev H., Wein B.B. Automatic categorization of medical images for content-based retrieval and data mining. *Computerized Medical Imaging and Graphics*, 29 (2-3), 143-155., 2005
- [18]. Shyu, C.-R., Brodley, C. E., Kak, A. C., Kosaka, A.. ASSERT: A Physician-in-the-Loop Content-Based Retrieval System for HRCT Image Databases. *Computer Vision and Image Understanding*, 75(1/2), 111-132. 1999.
- [19]. Jaramillo G.E., Branch Bedoya J.W. Doris: Sistema para la recuperación de imágenes de piezas Mecánicas y de Automatización Utilizando Descriptores de Textura. *Revista Avances en Sistemas e Informática*. 5(2), 131-136, 2008.