



**UNIVERSIDAD DE SONORA**

**DIVISIÓN DE CIENCIAS EXACTAS Y NATURALES**

**DEPARTAMENTO DE INVESTIGACIÓN EN FÍSICA**

---

**Programa de Doctorado en Ciencias (FÍSICA)**

---

**PROCESAMIENTO DE IMÁGENES Y ANÁLISIS ESPECTRAL DE  
FOURIER PARA LA DETECCIÓN DE CÁNCER DE PIEL**

**Tesis**

Que para cubrir parcialmente los requisitos necesarios para obtener el grado de

**Doctor en Ciencias (FÍSICA)**

Presenta:

**ESPERANZA GUERRA ROSAS**

Hermosillo, Sonora, México

Enero del 2017

# Universidad de Sonora

Repositorio Institucional UNISON



**"El saber de mis hijos  
hará mi grandeza"**



Excepto si se señala otra cosa, la licencia del ítem se describe como openAccess



"El saber de mis hijos  
hará mi grandeza"

# UNIVERSIDAD DE SONORA

## DIVISIÓN DE CIENCIAS EXACTAS Y NATURALES

### Departamento de Investigación en Física

#### Programa de Posgrado en Ciencias (Física)

El Jurado de Tesis abajo firmante, APRUEBA POR UNANIMIDAD el presente manuscrito de la TESIS intitulada "*Procesamiento de Imágenes y Análisis Espectral de Fourier para la Detección de Cáncer de Piel*" presentado por la **M.C. Esperanza Guerra Rosas** bajo la dirección del Dr. Josué Álvarez Borrego y la Codirección del Dr. Ángel Coronel Beltrán, dando así cumplimiento a la fase escrita del proceso de titulación del Programa de Doctorado en Ciencias (Física) de la Universidad de Sonora.

**Dr. Josué Álvarez Borrego**  
Profesor Investigador Titular D  
División de Física Aplicada  
Departamento de Óptica  
Centro de Investigación Científica y de  
Educación Superior de Ensenada, B. C.

**Dr. Marcelino Barboza Flores**  
Profesor Investigador Titular C  
Departamento de Investigación en Física  
Universidad de Sonora

**Dra. Selene Solorza Calderón**  
Profesor Investigador Titular C  
Facultad de Ciencias  
Universidad Autónoma de Baja California

**Dr. Abundio Dávila Álvarez**  
Investigador Titular C  
Centro de Investigaciones en óptica, A. C.

**Dr. Ángel Coronel Beltrán**  
Profesor Investigador Titular A  
Departamento de Investigación en Física  
Universidad de Sonora

**Vo.Bo. Dra. Susana Álvarez García**  
Coordinadora del Programa de  
Posgrado en Ciencias (Física)  
Universidad de Sonora



El saber de mis hijos  
hará mi grandeza  
**Posgrado en  
Ciencias (Física)**  
Departamento  
de Investigación  
en Física

En Hermosillo, Sonora a 10 de Enero de 2017.

Tesis defendida por:  
ESPERANZA GUERRA ROSAS  
y aprobada por el siguiente comité

---

Dr. Josué Álvarez Borrego  
Departamento de Óptica, CICESE

---

Dr. Ángel Coronel Beltrán  
Departamento de Investigación en  
Física, UNISON

---

Dr. Marcelino Barboza Flores  
Departamento de Investigación en  
Física, UNISON

---

Dra. Selene Solorza Calderón  
Facultad de Ciencias, UABC

---

Dr. Abundio Dávila Álvarez  
Centro de Investigación en Óptica

---

Dra. Susana Álvarez García  
Coordinadora del  
Programa de Doctorado en Ciencias  
(Física)

Resumen de la tesis de **Esperanza Guerra Rosas**, presentada como requisito parcial para la obtención del grado de **Doctor en Ciencias (Física)**.

## **PROCESAMIENTO DE IMÁGENES Y ANÁLISIS ESPECTRAL DE FOURIER PARA LA DETECCIÓN DE CÁNCER DE PIEL**

Resumen aprobado por:

---

Dr. Josué Álvarez Borrego  
Director

---

Dr. Ángel Coronel Beltrán  
Co-Director

En la actualidad el procesamiento digital de imágenes es utilizado en diferentes disciplinas como la física donde está incluida la óptica, la electrónica, la computación, las matemáticas, etc. El procesamiento de imágenes incluye un conjunto de técnicas aplicadas a una imagen, para identificar, caracterizar, clasificar y reconstruir imágenes de objetos, personas, fenómenos o señales, destacando información de interés para su análisis posterior. En los últimos años ha tenido una aplicación satisfactoria, esto se debe al desarrollo de nuevas herramientas de gran utilidad entre las que se incluyen diagnósticos médicos, exploración espacial, visión por computadora, entre otras. En este trabajo se presenta una metodología para detectar cáncer de piel, basada en procesamiento digital de imágenes y análisis espectral de Fourier sobre imágenes de manchas dermatológicas, aplicando los filtros clásico, inverso y no lineal ley-k.

La imagen a color se divide en sus componentes R, G, B y en la escala de grises para obtener las propiedades espectrales de cada canal, luego se realiza una medición de perfiles de intensidad con el objetivo de saber cuál es el canal que proporciona mayor información. La lesión se separa del resto de la imagen para obtener la función de máscara binaria. Se toma la imagen en un canal y se multiplica punto a punto por la máscara binaria, de esta manera se obtiene la imagen segmentada, la cual representa la matriz de datos de intensidad que contiene la información de la mancha de interés a analizar. La imagen segmentada se divide en 25 sub-imágenes para considerar sólo aquellas que contengan información mayor o igual a un tercio del total de su área correspondiente. A cada sub-imagen se le aplica algún filtro para pasar al dominio de las frecuencias y obtener una medición cuantitativa de patrones complejos. Para cada sub-imagen se calcula un índice espectral y para cada imagen se calcula un índice espectral promedio. Finalmente se obtiene un intervalo de confianza de índices espectrales, el cual es específico para el cáncer de piel, por lo tanto los índices de imágenes que se encuentren dentro de este intervalo serán diagnosticadas como cancerígenas. Los resultados obtenidos muestran un nivel de confianza del 95.4%.

Palabras clave: **Procesamiento digital de imágenes, análisis de Fourier, índice espectral.**

Abstract of the thesis presented by **Esperanza Guerra Rosas** as a partial requirement for the degree of Doctor of Science in Physics.

## **IMAGE PROCESSING AND FOURIER SPECTRAL ANALYSIS FOR DETECTION OF SKIN CANCER**

Abstract approved by:

---

Dr. Josué Álvarez Borrego  
Director

---

Dr. Ángel Coronel Beltrán  
Co-Director

At the present, the digital image processing is used in different disciplines such as physics, where optics, electronic, computing, mathematics, etc. are included. Image processing includes a set of techniques applied to an image to identify, classify and reconstruct images of objects, people, phenomena or signals, highlighting the interest information for further analysis. In the last years it has had a satisfactory application, this is due to the development of the new useful tools including medical diagnostics, space exploration, and computer vision, among others. In this work a methodology for detecting skin cancer, based on digital image processing and spectral Fourier analysis on images of dermatologic spots, applying the classic, inverse and non-linear law-k filters is presented.

The color image is divided into its components R, G, B and grayscale to obtain the spectral properties of each channel, then a measurement of intensity profile is done in order to know the channel providing more information. The lesion is separated from the rest of the image to obtain the binary mask function. The image on a channel is taken and multiplied point to point by the binary mask, in this way the segmented image is obtained, which represents the intensity data matrix that contains information of the interest spot to be analyzed. The segmented image is divided into 25 sub-images to consider only those containing information greater than or equal to one third of its total area corresponding. One filter is applied to each sub-image to calculate the frequencies domain and obtain a quantitative measurement of complex patterns. For each sub-image a spectral index is calculated, and for each image a mean of the spectral index is obtained. Finally a confidence interval of spectral indices, which is defined for skin cancer, is obtained; therefore the index of the images that are within this interval will be diagnosed as cancerous. The results show a confidence level of 95.4%.

**Keywords: Digital image processing, Fourier analysis, spectral index.**

## **Dedicatoria**

A mi madre y hermanos por todo su apoyo.

## **Agradecimientos**

A la UNISON por brindarme la oportunidad de realizar el doctorado.

Al departamento de investigación en Física de la Universidad de Sonora por permitirme ingresar al posgrado.

Al Dr. Josué Álvarez Borrego, director de tesis, por su apoyo y ayuda incondicional y por compartir sus conocimientos para el desarrollo de mi tesis.

A Dr. Mario Flores Acosta y a la Dra. Susana Álvarez García por su apoyo.

A los miembros del comité de seguimiento de tesis: Dra. Milka del Carmen Acosta Enríquez, Dr. Santos Jesús Castillo y Dr. Ángel Coronel Beltrán por sus comentarios y aportaciones durante el desarrollo de este trabajo.

A los miembros del comité de revisión de tesis: Dra. Selene Solorza Calderón, Dr. Marcelino Barboza Flores y Dr. Abundio Dávila Álvarez por la revisión y observaciones al documento de tesis.

Al CONACYT por el apoyo económico otorgado para realizar mis estudios de doctorado.



## Tabla de contenido

	Página
<b>Resumen</b> .....	<b>i</b>
<b>Abstract</b> .....	<b>ii</b>
<b>Dedicatoria</b> .....	<b>iii</b>
<b>Agradecimientos</b> .....	<b>iv</b>
<b>Lista de figuras</b> .....	<b>viii</b>
<b>Lista de figuras de los apéndices</b> .....	<b>x</b>
<b>Lista de tablas</b> .....	<b>xi</b>
<b>Capítulo 1. Introducción</b> .....	<b>1</b>
1.1 Justificación.....	2
1.2 Objetivos .....	3
1.2.1 Objetivo general.....	3
1.2.2 Objetivos específicos .....	3
1.3 Organización de la tesis.....	4
<b>Capítulo 2. Marco teórico</b> .....	<b>5</b>
2.1 Cáncer de piel.....	5
2.2 Procesamiento digital de imágenes .....	7
2.2.1 Etapas del procesamiento digital de imágenes .....	7
2.3 Imagen digital.....	12
2.4 Modelo de color RGB .....	13
2.5 Transformada de Fourier .....	17
2.5.1 Transformada de Fourier para una función unidimensional y su inversa.....	18
2.5.2 Transformada de Fourier para una función bidimensional y su inversa.....	19

## Tabla de contenido (continuación)

	Página
2.6 Propiedades de la transformada de Fourier .....	21
2.6.1 Linealidad .....	21
2.6.2 Desplazamiento en el dominio del espacio .....	21
2.6.3 Desplazamiento en el dominio de la frecuencia .....	22
2.6.4 Simetría .....	22
2.6.5 Rotación .....	22
2.6.6 Escalamiento .....	23
2.6.7 Teorema de Parseval .....	23
2.6.8 Teorema de la convolución .....	23
2.6.9 Teorema de la correlación .....	24
<b>Capítulo 3 Metodología .....</b>	<b>26</b>
3.1 Banco de imágenes .....	26
3.2 Análisis multiespectral .....	27
3.3 Segmentación de imágenes .....	30
3.4 Sub-imágenes .....	32
3.5 Filtros digitales .....	34
3.6 Filtros en el dominio de la frecuencia .....	34
3.7 Filtro clásico acoplado (CMF) .....	35
3.8 Filtro inverso (IF) .....	35
3.9 Filtro no lineal ley k .....	36
3.10 Índice espectral .....	36
<b>Capítulo 4. Resultados .....</b>	<b>40</b>

**Tabla de contenido (continuación)**

	Página
<b>Conclusiones .....</b>	<b>48</b>
<b>Referencias.....</b>	<b>50</b>
<b><i>Apéndice A</i>.....</b>	<b>53</b>
<b><i>Apéndice B</i>.....</b>	<b>57</b>

## Lista de figuras

	Página
Figura 1	Capas de la piel ..... 6
Figura 2	Etapas fundamentales del procesamiento digital de imágenes ..... 8
Figura 3	Imagen a color RGB considerada como una función en dos dimensiones. . 12
Figura 4	Imagen digital. .... 13
Figura 5	Espectro visible ..... 14
Figura 6	Matrices bidimensionales de una imagen RGB. .... 14
Figura 7	Cubo de color RGB. .... 15
Figura 8	Imagen a color $f(x, y)$ dividida en los canales RGB y escala de grises. .... 16
Figura 9	Imágenes de cáncer de piel. .... 27
Figura 10	Perfiles de intensidad, (a) conjunto de vectores de intensidad, (b) valores medios de los perfiles de intensidad del canal rojo, (c) valores medios del perfil de intensidad del canal verde, (d) valores medios del perfil de intensidad del canal azul y (e) valores medios del perfil de intensidad de la escala de gris. .... 29
Figura 11	Perfiles de intensidad de todos los canales y escala de gris. .... 30
Figura 12	Segmentación (a) imagen original, (b) imagen en escala de gris y (c) máscara binaria. .... 31
Figura 13	Sub-imágenes de la máscara binaria. .... 32
Figura 14	Sub-imágenes $I_{w_j}^{\lambda_c}(x, y)$ , $j = 1, 2, 3, \dots, 25$ . .... 33
Figura 15	Sub-imágenes $I_{w_j}^{\lambda_c}(x, y)$ que contienen información mayor o igual a un tercio de su área. .... 34
Figura 16	Diagrama de bloques para obtener el índice espectral de una imagen. .... 39
Figura 17	Clasificación de lesiones (benignas y malignas). Diagrama de cajas de índices espectrales mediante el filtro Ley-k. (a) Canal rojo, (b) canal verde, (c) canal azul y (d) escala de grises. .... 41

## Lista de figuras (continuación)

	Página
Figura 18	Carcinoma basocelular. Diagrama de cajas de índices espectrales usando el filtro Ley-k: (a) canal rojo, (b) canal verde, (c) canal azul y (d) escala de grises. .... 43
Figura 19	Carcinoma epidermoide. Diagrama de cajas de índices espectrales usando el filtro Ley-k: (a) canal rojo, (b) canal verde, (c) canal azul y (d) escala de grises. .... 44
Figura 20	Melanoma. Diagrama de cajas de índices espectrales usando el filtro Ley-k: (a) canal rojo, (b) canal verde, (c) canal azul y (d) escala de grises. .... 44

# Lista de figuras de los apéndices

	Página
Figura A.1	Imagen a color..... 53
Figura A.2	Obtención de sub-imágenes para su análisis: (a) matriz de sub-imágenes $I_{w_j}^{\lambda_G}(x, y)$ y (b) sub-imágenes..... 53
Figura A.3	Densidades espectrales de las sub-imágenes obtenidas mediante el filtro no lineal ley-k. .... 54
Figura A.4	Densidades espectrales binarizadas. .... 55
Figura A.5	Densidades: (a) densidad espectral obtenida al aplicar el filtro no lineal ley-k y (b) densidad espectral binarizada. .... 56
Figura B.1	Pantalla principal. .... 57
Figura B.2	Lectura de la imagen. .... 57
Figura B.3	Análisis de la imagen. .... 58
Figura B.4	Cambio de imagen. .... 59
Figura B.5	Análisis de una nueva imagen..... 59

## Lista de tablas

		Página
Tabla 1	Intervalos obtenidos con el filtro no lineal ley-k (media $\pm 2EE$ ).....	42
Tabla 2	Intervalos para el carcinoma basocelular (media $\pm 2EE$ ) .....	45
Tabla 3	Intervalos para el carcinoma epidermoide (media $\pm 2EE$ ) .....	45
Tabla 4	Intervalos para el melanoma (media $\pm 2EE$ ) .....	46
Tabla 5	Comparación con otros trabajos.....	46

## **LISTA DE PUBLICACIONES PRODUCIDAS POR ÉSTA INVESTIGACIÓN**

### **Artículo en revista con arbitraje:**

Guerra-Rosas Esperanza, Álvarez-Borrego Josué, “*Methodology for diagnosing of skin cancer on images of dermatologic spots by spectral analysis*”, Biomedical Optics Express, 6(10), 242232, (September 09, 2015); DOI:10.1364/BOE.6.003876

### **Artículo en memoria de congreso internacional con arbitraje:**

Guerra-Rosas Esperanza, Álvarez-Borrego Josué, Coronel-Beltrán Ángel, “*Diagnosis of skin cancer using image processing*”, Athens, Greece, AIP Conf. Proc. 1618, 147 (2014), 4-7 April, doi: 10.1063/1.4897704, <http://dx.doi.org/10.1063/1.4897704>

### **Resumen en memoria de congreso internacional:**

Guerra-Rosas Esperanza, Álvarez-Borrego Josué, “*Automatic diagnosis of pigmented skin lesions based on digital images*”, MOPM 2015 (Mexican Optics and Photonics Meeting), León, Guanajuato México, Septiembre 2015

### **Resumen en memorias de congresos nacionales:**

Guerra-Rosas Esperanza, Álvarez-Borrego Josué, “*Análisis de imágenes digitales para el diagnóstico de cáncer de piel*”, Congreso de instrumentación SOMI 2015, Durango, Durango México, Octubre 2015

Guerra-Rosas Esperanza, Álvarez-Borrego Josué, “*Detección de cáncer de piel mediante procesado de imágenes y análisis espectral*”, VI Congreso Nacional de Tecnología Aplicada a Ciencias de la Salud, Puebla, Puebla México, Junio 2015

Guerra-Rosas Esperanza, Álvarez-Borrego Josué, “*Diagnóstico de cáncer de piel mediante la obtención de índices espectrales*”, V Congreso Nacional de Tecnología Aplicada a Ciencias de la Salud. Puebla, Puebla México, Junio 2014

### **Estadía Nacional:**

Estancia nacional en CICESE a cargo del Dr. Josué Álvarez Borrego, Enero - Junio de 2014



# Capítulo 1

---

## Introducción

Actualmente los avances en distintas áreas de las ciencias, han logrado un crecimiento de información, lo cual genera una dificultad para entender, estudiar y analizar las diferentes áreas debido a la existencia de pocos especialistas.

Los problemas de salud son una gran preocupación en el mundo, por lo que proteger la salud es uno de los retos mundiales, esto requiere una detección oportuna de enfermedades para aumentar la calidad de vida del hombre. En los últimos años, en el campo de las nuevas tecnologías se han desarrollado muchas aplicaciones con el propósito de facilitar la información existente a los investigadores, ya que ellos continuamente buscan formas para mejorar la condición y calidad de vida del hombre al detectar y tratar diversas enfermedades.

Constantemente se tiene el interés de tener una mejor salud, sin embargo en ocasiones puede aumentar el riesgo de perderla. Actualmente una de las enfermedades que afecta al ser humano es el cáncer de piel. Esta enfermedad representa un grave problema de salud, que en los últimos años la búsqueda de un diagnóstico clínico preciso de tumores cutáneos ha generado una constante preocupación por parte de los dermatólogos. En la actualidad se han desarrollado métodos de diagnóstico mediante el análisis digital de imágenes, con el desarrollo de nuevas metodologías se puede ayudar a detectar enfermedades en forma precoz.

En este trabajo se presenta el desarrollo e implementación de una metodología basada en el procesamiento de imágenes y análisis espectral, la cual puede facilitar la identificación y detección de cáncer de piel mediante una imagen, cabe mencionar que esta metodología se

puede implementar para el análisis de alguna otra enfermedad de la piel manifestada en manchas.

El reconocimiento de patrones es un área dentro del procesamiento de imágenes de dominio multidisciplinario que permite identificar, caracterizar, clasificar y reconstruir objetos, personas, fenómenos, señales, dentro de una imagen. Esta área se ha reflejado en la medicina, la astronomía, la geología, la microscopía, etc., incluye un conjunto de técnicas aplicadas a una imagen que permiten destacar información de interés para un análisis posterior. Actualmente ha tenido una variedad de aplicaciones que incluyen diagnósticos médicos, exploración espacial, visión por computadora, etc. Para el desarrollo de este trabajo se obtuvo un banco de imágenes con muestras de imágenes de lesiones cancerígenas y benignas proporcionadas por médicos especialistas. Estas imágenes fueron previamente clasificadas como benignas o cancerígenas. De cada imagen se obtuvo información morfológica, dentro de la metodología se aplicaron diferentes filtros de frecuencia mediante la transformada de Fourier de la imagen, para obtener finalmente un rango de índices espectrales que permite obtener un diagnóstico.

## **1.1 Justificación**

En los últimos años el reconocimiento de patrones dentro del procesamiento de imágenes ha tenido una aplicación satisfactoria en diferentes áreas dentro del ámbito científico, la medicina, la biología, la industria, entre otras, lo cual ha permitido el desarrollo de herramientas eficientes y fáciles de usar.

Las imágenes digitales son de gran importancia en varias aplicaciones para interpretar y obtener información. Una mancha o lesión en la piel puede indicar la presencia de cáncer, lo cual ha generado el interés en desarrollar una metodología para analizar imágenes de manchas de piel.

Por lo tanto el desarrollo de una nueva metodología mediante procesamiento de imágenes y análisis espectral, será una contribución y una herramienta de ayuda para el diagnóstico de

cáncer de piel, facilitando el análisis de resultados para el médico especialista, la cual le permitirá tomar una mejor decisión, además de ser una herramienta no invasiva de fácil implementación para el paciente.

## **1.2 Objetivos**

### **1.2.1 Objetivo general**

Desarrollar un algoritmo basado en la técnica de procesamiento digital de imágenes y análisis espectral de Fourier, para clasificar y detectar manchas en piel con el propósito de brindar una herramienta de apoyo para el diagnóstico automático de cáncer de piel.

### **1.2.2 Objetivos específicos**

Para llevar a cabo el objetivo general se definen a continuación los objetivos específicos:

- Construir un banco de imágenes de lesiones benignas y cancerígenas.
- Conocer la morfología para cada mancha que sea causante de cáncer de piel.
- Filtrar las imágenes en escala de grises y espacio de color RGB.
- Realizar la selección y caracterización de imágenes haciendo una transformación de datos a un formato común, explorarlos y analizarlos.
- Construir un algoritmo para clasificación de las manchas de piel.
- Hacer una exploración de las imágenes proporcionadas, para analizar sus características.
- Aplicar filtros a las imágenes para cambiar al dominio de la frecuencia.
- Obtener las densidades espectrales de las imágenes.
- Realizar un análisis de patrones complejos de las densidades espectrales para la obtención de índices espectrales.
- Evaluar y verificar el funcionamiento, eficiencia, el intervalo de confianza estadístico y calidad del algoritmo desarrollado.

- Desarrollar una interfaz gráfica como herramienta de apoyo para un usuario o para la toma de decisiones del médico general o médico especialista.
- Evaluar la funcionalidad del sistema desarrollado.

### **1.3 Organización de la tesis**

La presente tesis está conformada por 5 capítulos.

En el capítulo 1 se presenta la introducción. En el capítulo 2 se presenta una breve descripción acerca del cáncer de piel, luego se hace una descripción del procesamiento digital de imágenes y en base a esto se mencionan algunos trabajos relacionados con técnicas para diagnosticar lesiones de piel mediante imágenes digitales; además, se presenta una definición de lo que es una imagen digital y la transformada de Fourier para funciones continuas y discretas para una y dos dimensiones, así como algunas de sus principales propiedades matemáticas, donde están incluidos los teoremas de Parseval, de convolución y de correlación.

El capítulo 3 contiene los pasos para llevar a cabo la metodología. Se presenta información del banco de imágenes utilizado, se muestra el análisis multiespectral de las imágenes, se define el uso de sub-imágenes, se presenta el uso de filtros digitales para trabajar sobre el dominio de las frecuencias y finalmente se obtiene el valor numérico llamado índice espectral.

En el capítulo 4 se presentan los resultados, en esta sección se muestran las gráficas de cajas obtenidas para las medias de los índices espectrales tanto de las imágenes de lesiones benignas como de las imágenes cancerígenas, también se presentan las gráficas para cada uno de los tipos de cáncer de piel y las lesiones benignas. Además, se incluyen las tablas comparativas de los diferentes intervalos obtenidos para lesiones cancerígenas y lesiones benignas.

Posteriormente en el capítulo 5 se presentan las conclusiones de este trabajo.

## Capítulo 2

---

### Marco teórico

#### 2.1 Cáncer de piel


El cáncer es una enfermedad causada por el desarrollo y crecimiento incontrolado de células anormales en cualquier parte del cuerpo, existen diferentes tipos de cáncer que son clasificados de acuerdo al tejido en el cual se originan las células cancerosas.

El cuerpo humano está formado por trillones de células vivas, las células normales crecen y se dividen para crear nuevas células a medida que el cuerpo las requiera y finalmente mueren de forma normal.

La piel es el órgano más grande del cuerpo humano, está constituido por varias capas; las principales son: la epidermis que es la capa externa, la dermis es la capa cubierta por la epidermis y la hipodermis que es la capa más profunda de la piel (Korotkov y Garcia, 2012). En la figura 1 se muestran las capas principales de la piel.

El cáncer de piel es una de las enfermedades más frecuente en el ser humano causada por el desarrollo de células cancerosas en cualquier capa de la piel. Los tres principales tipos de cáncer de piel son el carcinoma basocelular, el carcinoma epidermoide y el melanoma (Eide et al., 2013; American Cancer Society, 2015). El carcinoma basocelular es el más común de los tres, sin embargo es el menos peligroso si se detecta a tiempo, surge en las células basales que se encuentran en la capa más profunda de la piel, generalmente en partes del cuerpo que son expuestas al sol, como la cara, cabeza, cuello, orejas, hombros y espalda, sin embargo se

localiza con mayor frecuencia en la cara y raramente puede causar metástasis (Telfer et al., 2008; Cricker et al., 2014; Lacy y Alwan, 2013; Ogden y Telfer, 2009).



**Figura 1.** Capas de la piel (<http://www.cancer.gov/publications/patient-education/skin.pdf>).

El carcinoma epidermoide se origina en las células escamosas que conforman las capas superiores de la piel (epidermis), puede alcanzar grandes tamaños, si no es tratado a tiempo puede causar metástasis, por lo general surge en partes del cuerpo que son expuestas a la luz ultravioleta tales como piernas o pies (Ogden y Telfer, 2009), generalmente se presenta como un nódulo, una pápula o tumor (Lacy y Alwan, 2013). El melanoma es el menos común, sin embargo es el más agresivo (Saraiya et al., 2014), puede aparecer repentinamente en cualquier parte de la piel, los lunares son uno de los orígenes de este tipo de cáncer y afecta a personas de piel clara u oscura. Al igual que el carcinoma basocelular y epidermoide, el melanoma casi siempre es curable si se detecta a tiempo (Ogden y Telfer, 2009; Korotkov y García, 2012). Existen otros tipos de cáncer de piel como pueden ser carcinomas de glándulas sebáceas, sudoríparas, sarcomas, etc., sin embargo son de observación rara (Gutiérrez-Vidrio, 2003).

En los últimos años, se ha incrementado la incidencia de cáncer de piel (Ogden y Telfer, 2009) en Europa, Asia y Estados Unidos. Los principales factores de riesgo son el color de la piel, (generalmente afecta a personas con piel blanca), la exposición a la luz ultravioleta, por lo general la luz solar es la fuente principal de rayos UV-A, UV-B y UV-C, la edad avanzada, la genética y el historial clínico de cáncer. La aparición de una nueva mancha en

la piel con cambios de tamaño, forma y color puede ser una señal de cáncer, una detección temprana puede evitar la muerte (Berg y Best, 2011).

Las lesiones dermatológicas constituyen un gran problema epidemiológico, en las últimas décadas se ha detectado un gran incremento en la población. Su identificación temprana proporciona una supervivencia a aquellos que la padecen.

## **2.2 Procesamiento digital de imágenes**

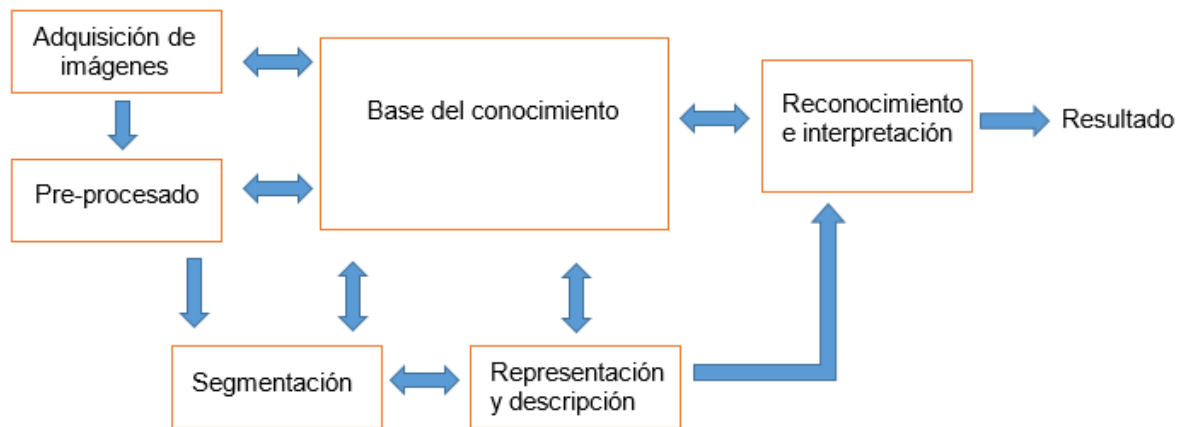
El procesamiento digital de imágenes constituye un conjunto de técnicas y procesos matemáticos aplicados a una imagen, con el objetivo de mejorar la calidad o facilitar la búsqueda de información contenida en dicha imagen, además es un área de investigación que está muy relacionado con el tratamiento de señales, ya sea en dos o tres dimensiones.

Hoy en día el procesamiento de imágenes ha adquirido un papel importante en diversas áreas donde se incluyen estudios de física, matemáticas, electrónica, computación, medicina, astronomía, geología, microscopía, biología, etc., cuenta con un amplio rango de aplicaciones, siendo un área multidisciplinaria, tiene la ventaja de procesar grandes cantidades de información, es muy útil como herramienta de medición, ya que permite observar intervalos con alta o baja frecuencia de forma automática.

### **2.2.1 Etapas del procesamiento digital de imágenes**

Las etapas fundamentales que se llevan a cabo en el procesamiento de imágenes digitales (González y Woods, 2008) se presentan en la figura 2. La primera etapa es la *adquisición de imágenes*, que consiste en la obtención de una imagen mediante un dispositivo de captura, por ejemplo una cámara CCD y posteriormente esta imagen es digitalizada. El siguiente paso es el *pre-procesamiento*, que tiene como objetivo mejorar la imagen aplicando diferentes técnicas para suavizar o eliminar ruido, realzar o aumentar el contraste de la imagen, detección de puntos, líneas y bordes para la corrección de defectos visuales en la imagen, entre otras cosas, de tal manera que con estas técnicas la cantidad de información no se modifica sustancialmente. La etapa de *segmentación* consiste en extraer objetos de interés

presentes en una imagen, es decir el objeto es separado del fondo de la imagen. En la *representación y descripción* se extraen características de la imagen para obtener información cuantitativa que permita diferenciar entre un objeto y otro. Posteriormente en la etapa de *reconocimiento e interpretación* se asigna una etiqueta al conjunto de objetos reconocidos en base a la etapa anterior para obtener el resultado de forma automatizada. La base del conocimiento contiene la información y los procesos llevados a cabo para la solución de un problema o para obtener un resultado, además permite guiar las operaciones de cada etapa, así como la interacción entre ellas.



**Figura 2.** Etapas fundamentales del procesamiento digital de imágenes.

En los últimos años se han desarrollado metodologías basadas en procesamiento de imágenes usando algoritmos o sistemas para la detección y clasificación por medio de técnicas y métodos computacionales, los cuales han sido aplicados en la solución de problemas médicos. Estas metodologías pueden ser una herramienta efectiva, especialmente cuando no se encuentra presente un médico especialista, por otra parte es una herramienta no invasiva para el paciente (Korotkov y Garcia, 2012; U.S. Preventive Services Task Force, 2001; Rahman y Bhattacharya, 2010).

Investigaciones recientes muestran estudios y trabajos relacionados con imágenes de lesiones de piel pigmentadas para su diagnóstico y clasificación, con el objetivo de proporcionar un diagnóstico preciso. En la literatura se han reportado diversos trabajos desarrollados con



herramientas basadas en procesamiento de imágenes aplicadas en el área médica. A continuación se detallan algunos trabajos de investigación.

Gola et al. (2011) desarrollaron una herramienta dermatológica automatizada para identificar melanoma. Sus algoritmos se basan en identificar tres categorías: pigmentación reticular, globular y azul homogénea. Un aspecto importante en este trabajo es extraer la forma de la lesión de la piel, de esta manera ellos obtienen las características de interés. Uno de los inconvenientes fue que los algoritmos no pueden hacer una decisión final, por lo que ellos desarrollaron un sistema para correlacionar todos los algoritmos con el fin de obtener un diagnóstico correcto.

Rahman y Bhattacharya (2010) propusieron un método similar para reconocer el melanoma. Su trabajo consistió en desarrollar un sistema de decisión, en el cual usaron diferentes clasificadores, tales como máquinas de soporte vectorial (SVMs), vecino cercano (K-NNs) y la probabilidad del máximo gaussiano (G-ML). Uno de los aspectos importantes de este trabajo fue obtener la morfología de la lesión, para esta se aplicó el método de segmentación basado en umbralización, de esta manera se obtuvo como resultado una máscara que contiene el área de la lesión en escala de gris. De esta máscara se extrajeron las características necesarias para entrenar los respectivos clasificadores y posteriormente construir un solo clasificador. Al hacer una evaluación de cada uno de los clasificadores, se obtuvo que el porcentaje más alto en precisión de uno de los clasificadores fue de 72.45%. Finalmente con este método se clasificó el melanoma, lesiones benignas y nevos displásicos.

Cavalcanti y Scharcanski (2011) propusieron un método para clasificar lesiones de piel pigmentada como benignas o malignas, mediante los clasificadores de vecino cercano y vecino cercano por medio de un árbol de decisión. A la imagen se le aplicó un pre-procesamiento, convirtiéndola del espacio de color RGB al espacio de color HSV para atenuar los efectos de sombreado. Patrones de color y textura de la imagen son considerados para realizar la segmentación de la misma, además se aplicaron operaciones para eliminar imperfecciones causadas por ruido. Un conjunto de características es extraído de la imagen segmentada de acuerdo a la regla ABCD (Asimetría, irregularidad de bordes, variación de

color y diámetro), ambos clasificadores fueron entrenados con estas características. Los resultados para predecir una lesión como benigna o maligna mostraron un 94.54 % de exactitud.

La metodología propuesta por Jaleel et al. (2012) está basada en técnicas de procesamiento de imágenes y el uso de redes neuronales artificiales. Al igual que Gola et al. (2011) su objetivo principal fue clasificar el melanoma de otras enfermedades de la piel. Las imágenes fueron pre-procesadas para remover el ruido presente en ellas, después es aplicado el filtro de la mediana para suavizar la imagen. El método de segmentación por umbral se aplicó para obtener la imagen segmentada y binarizada. Como parte de la metodología se entrenó una red neuronal, tomando como características la media, la desviación estándar, la media absoluta y las normas L1 y L2, las cuales se obtuvieron al hacer una transformación de la imagen aplicando el método 2D wavelet. En base a los resultados obtenidos sólo se reportó una tasa de precisión buena, sin embargo se menciona que el sistema puede ser mejorado.

Dada una imagen dermatoscópica Sadeghi et al. (2011) desarrollaron una metodología para clasificar la presencia o ausencia de redes pigmentadas en la piel. Inicialmente la imagen fue pre-procesada con el objetivo de remover el ruido de baja frecuencia, para esto se aplicó el filtro pasa altas, este paso se llevó a cabo bajo diferentes espacios de color (espacio de color NTSC,  $L^*a^*b$  y RGB). Las mallas o estructuras cíclicas representan una región de red pigmentada en la piel. El filtro laplaciano de la gaussiana LoG permite destacar las regiones donde hay cambios bruscos de intensidad en una imagen y se utiliza con frecuencia para detectar bordes, en esta metodología se aplicó este filtro para encontrar las mallas o estructuras cíclicas ya que estas representan la presencia de una región de red pigmentada. Mediante un análisis de ocho componentes conectados se unió el conjunto de sub-gráficos, posteriormente se removió el ruido y las estructuras no deseadas, a partir de este gráfico se obtuvo la densidad de radio, la cual fue usada para detectar la red pigmentada. El porcentaje de clasificación reportado fue de 94.3%.

Otro trabajo para detectar redes pigmentadas en imágenes dermatoscópicas fue el propuesto por Barata et al. (2012). Elementos de ruido como cabellos y reflexiones causadas por el gel

dermatoscópico fueron removidos de la imagen en escala de gris. Sobre la intensidad de la imagen se aplicaron filtros direccionales (filtros de Gabor 2D y gaussiano) para mejorar la red pigmenta y se generó una máscara de red binaria usando la geometría o la organización espacial de la imagen. En base a diferentes características a la imagen binaria se le asignó la etiqueta con red pigmentada o sin red pigmentada. Finalmente las características extraídas fueron utilizadas para entrenar el clasificador usando el algoritmo AdaBoost. Este algoritmo fue entrenado con un total de 200 imágenes dermatoscópicas (88 imágenes con red pigmentada y 112 sin ella). El porcentaje de clasificación reportado en este trabajo fue 82.1% de clasificación.

Una metodología para detectar redes pigmentadas o patrones vasculares atípicos fue la propuesta por Betta et al. (2006). Esta metodología está basada en la combinación de una técnica estructural y espectral. La técnica estructural permite identificar la textura definida por discontinuidades tales como líneas o puntos y se obtiene comparando la imagen monocromática con la imagen a la cual se le aplicó el filtro de la mediana. La técnica espectral está basada en el análisis de Fourier sobre la imagen para obtener el periodo espacial de la textura, de esta forma se crea una máscara de red con regiones, la cual es unida con la máscara binaria, donde el área de la lesión y la red pigmentada son realizadas. Finalmente, para cuantificar la naturaleza de la red, se obtuvieron dos índices relacionados con la variabilidad cromática y espacial. Para validar el funcionamiento de este método se evaluaron 30 imágenes.


Orozco et al. (2010) colectaron espectros de reflexión difusa en la piel de pacientes y extrajeron las características más importantes de la señal espectral, para correlacionarlas con su respectiva patología mediante el uso de algoritmos de clasificación. La mayoría de estudios antes mencionados así como Celebi et al. (2007), Smaoui y Bessassi (2013) y Premaladha y Ravichandran (2014) incluyen etapas similares. Generalmente las etapas más utilizadas son: (i) adquisición para formar el conjunto de imágenes a analizar, (ii) segmentación (en la que se incluyen diversos métodos como técnicas basadas en bordes, umbralización, segmentación de histograma, crecimiento de regiones, etc), (iii) extracción

de características para su análisis, (iv) clasificación o detección de la lesión para su diagnóstico.

### 2.3 Imagen digital

Una imagen puede definirse como una función bidimensional de intensidad de luz  $f(x, y)$  de tamaño  $M \times N$  donde  $(x, y)$  representan las coordenadas espaciales y  $f$  representa la amplitud (luminosidad o nivel de gris) de la imagen en el punto  $(x, y)$ , los valores de  $(x, y)$  y  $f$  son cantidades finitas y discretas.


La imagen contiene información visual y real del mundo físico, también puede ser representada como una señal (función en el tiempo), donde cada punto está asociado a un valor de intensidad. La figura 3 representa una imagen como una función bidimensional.



**Figura 3.** Imagen a color RGB considerada como una función en dos dimensiones.

Una imagen digital se refiere a una imagen definida por la función  $f(x, y)$  que ha sido discretizada tanto en las coordenadas espaciales como en el brillo, además se puede considerar como una matriz, donde los índices de una fila y columna indican un punto en la imagen y el valor del elemento de la matriz correspondiente a ese punto contiene el valor de

intensidad, como se indica en la figura 4. La colección de puntos en una matriz bidimensional es la representación más simple de una imagen digital.




**Figura 4.** Imagen digital.

La frecuencia espacial de una imagen digital se define como el número de ciclos por unidad de longitud en una dirección dada, donde un ciclo se entiende al pasar de un nivel de brillo máximo a un nivel de brillo mínimo. Las zonas donde se presentan cambios o transiciones graduales se conocen como bajas frecuencias y las zonas donde hay cambios bruscos y rápidos como los bordes o ruidos se conocen como altas frecuencias. De acuerdo a lo anterior una imagen se puede modelar a partir de funciones armónicas mediante el análisis de Fourier. La información de las líneas de una imagen se pueden transformar en una serie de funciones cosenoidales con amplitud y frecuencia.

## **2.4 Modelo de color RGB**

El color se produce por la reflexión de la luz sobre algún objeto. El espectro de luz visible que el ojo humano es capaz de percibir abarca un rango de longitudes de onda que va de 380 nm (violeta) a 740 nm (rojo), ya que en este rango se encuentran los modelos de color (en la figura 5 se muestra el espectro de luz visible por los humanos). Específicamente el modelo


de color es un sistema de coordenadas que pertenece a un sub-espacio y cada punto representa un color.



**Figura 5.** Espectro visible (<http://ireneadh.blogspot.mx/>).

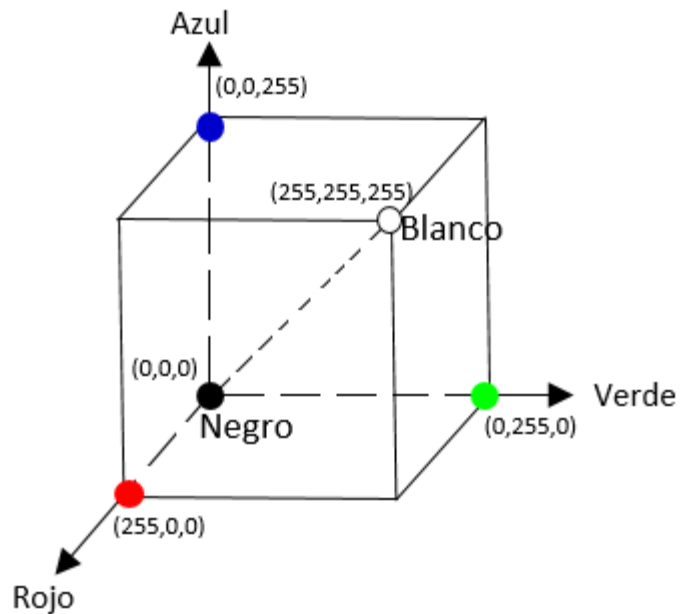
Los modelos de color existentes son el RGB, CMY, YUV, YIQ, YCbCr, HSI y CIELAB y se utilizan de acuerdo a la aplicación que se requiera. El modelo de color RGB es el más utilizado en el procesamiento de imágenes digitales y se basa en los tres colores primarios Rojo (R), Verde (V) y Azul (B), la mayoría de cámaras fotográficas para la adquisición de imágenes digitales utilizan este formato.

Una imagen a color (RGB) está constituida por tres matrices bidimensionales de grises correspondientes a los planos R, G y B con valores de 0 a 255 (uint 8), como lo indica la figura 6, por lo tanto la combinación de estos planos forman un solo color (RGB).




**Figura 6.** Matrices bidimensionales de una imagen RGB.

En el procesamiento de imágenes cada color es codificado como un byte = 8 bits, sin embargo también se pueden utilizar más bits. El color rojo se obtiene con  $(255, 0, 0)$ , el verde con  $(0, 255, 0)$  y el azul con  $(0, 0, 255)$ , el negro se obtiene cuando las componentes son cero  $(0, 0, 0)$  y el blanco se obtiene con el máximo valor de los tres colores primarios  $(255, 255, 255)$ . Un píxel se define como la unidad más pequeña de una imagen digital, cada píxel contiene un color homogéneo y su valor se puede representar por un sistema cartesiano como se muestra en la figura 7. Los colores se definen por un punto en el cubo, donde los valores RGB se encuentran en tres vértices, el color negro corresponde al origen y el color blanco al vértice más alejado del origen, la escala de grises se encuentra a lo largo de la diagonal que une al punto blanco con el negro.



**Figura 7.** Cubo de color RGB.

En la figura 8 se puede observar la imagen de cada uno de los canales que constituyen la imagen a color presentada en la figura 3 definida por la función  $f(x, y)$ , también se muestra la imagen en escala de grises.



**Figura 8.** Imagen a color  $f(x, y)$  dividida en los canales RGB y escala de grises.

La metodología desarrollada se aplicó a cada uno de los canales, por lo tanto se obtuvieron resultados independientes para cada canal.



## 2.5 Transformada de Fourier

La transformada de Fourier es aplicada a señales continuas en el tiempo o en el espacio, además requiere calcular una integración con extremos infinitos, que no en todos los casos puede ser fácil de resolver, sin embargo este tipo de señales, debido a la manera en que las medimos, llegan a ser discretas para su análisis. Por tanto, una variante de la transformada de Fourier para señales continuas es la transformada discreta de Fourier (DFT por sus siglas en inglés), que se aplica a una señal que ha sido muestreada o discretizada.

La transformada de Fourier es una herramienta importante en el procesamiento de imágenes, la cual es usada para descomponer una imagen en sus componentes senos y cosenos con diferente amplitud, frecuencia y fase, los cuales definen los cambios espaciales o temporales que ocurren en una señal, además permite analizar el espectro de la misma. Transforma una señal de entrada en el dominio del espacio o del tiempo a una señal de salida en el dominio de la frecuencia sin alterar su información. Es utilizada en un amplio rango de aplicaciones, tales como análisis frecuencial, filtrado y reconstrucción de imágenes.

Las condiciones de existencia de la transformada de Fourier como lo menciona Bracewell (1978), para una determinada función son:

- 1) La función  $f(x)$  debe tener un número finito de discontinuidades en un periodo.
- 2) La función  $f(x)$  debe tener un número finito de máximos y mínimos en un periodo.
- 3) La función  $f(x)$  es absolutamente integrable, sobre su periodo, es decir:

$$\frac{1}{T} \int_{-T/2}^{T/2} |f(x)dx| < \infty . \quad (1)$$

Sin embargo, en problemas de interés práctico existen funciones que no cumplen con estas condiciones de existencia, para este caso se puede definir el límite para una secuencia de funciones que sea transformable.

### 2.5.1 Transformada de Fourier para una función unidimensional y su inversa

La transformada de Fourier para una señal continua unidimensional se define como (Papoulis, 1962, p. 1; Goodman, 2005; Gonzalez y Woods, 1992, p.82):

$$F(u) = \int_{-\infty}^{\infty} f(x)e^{-i2\pi ux} dx, \quad (2)$$

y la transformada inversa de Fourier está dada por:

$$f(x) = \int_{-\infty}^{\infty} F(u)e^{i2\pi ux} du, \quad (3)$$

donde  $i = \sqrt{-1}$ ,  $u$  representa una variable continua en el dominio de la frecuencia y  $x$  una variable continua en el dominio del espacio.

En general la transformada de Fourier de una función real es compleja y está compuesta por una parte real  $Re(u)$  y una parte imaginaria  $Im(u)$ , por lo cual se puede expresar en forma polar compleja como:

$$F(u) = |F(u)|e^{-i\theta(u)}, \quad (4)$$

donde

$$|F(u)| = \sqrt{Re(F(u))^2 + Im(F(u))^2}, \quad (5)$$

es la magnitud de la transformada de Fourier o espectro de Fourier de  $f(x)$  y

$$\theta(u) = \tan^{-1} \left[ \frac{Im(F(u))}{Re(F(u))} \right], \quad (6)$$

es el ángulo de fase o espectro de fase de la transformada de Fourier.

La transformada de Fourier de una función discreta  $f(x)$ , para los valores de  $x=0,1,2,3,\dots,M-1$  y de tamaño  $M$  está definida por:

$$F(u) = \frac{1}{M} \sum_{x=0}^{M-1} f(x) e^{-i2\pi ux/M}, \quad \text{para } u=0,1,2,3,\dots,M-1, \quad (7)$$

y la transformada de Fourier inversa para una función discreta:

$$f(x) = \sum_{u=0}^{M-1} F(u) e^{i2\pi ux/M}, \quad \text{para } x=0,1,2,3,\dots,M-1, \quad (8)$$

donde  $u$  es una variable discreta en el dominio de la frecuencia y  $x$  es una variable discreta en el dominio espacial.

### 2.5.2 Transformada de Fourier para una función bidimensional y su inversa

La transformada de Fourier bidimensional está definida por:

$$F(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-i2\pi(ux+vy)} dx dy, \quad (9)$$

y su transformada inversa de Fourier bidimensional se define como:

$$f(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(u, v) e^{i2\pi(ux+vy)} du dv, \quad (10)$$

si  $f(x, y)$  es continua e integrable y  $F(u, v)$  es integrable, entonces existe este par de transformadas de Fourier, donde  $(u, v)$  son variables continuas que representan las frecuencias y  $(x, y)$  son variables continuas representadas en el espacio.

Para el caso de una función discreta bidimensional  $f(x, y)$  de tamaño  $M \times N$  la transformada discreta de Fourier está dada por:

$$F(u, v) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-i2\pi(ux/M + vy/N)}, \quad (11)$$

para valores de  $u = 0, 1, 2, 3, \dots, M-1$  y  $v = 0, 1, 2, 3, \dots, N-1$ .

La transformada discreta inversa de Fourier para la función discreta  $F(u, v)$  está definida por:

$$f(x, y) = \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u, v) e^{i2\pi(ux/M + vy/N)}, \quad (12)$$

para valores de  $x = 0, 1, 2, 3, \dots, M-1$  y valores de  $y = 0, 1, 2, 3, \dots, N-1$ .

Análogamente como en el caso unidimensional, la transformada de Fourier en forma polar, la amplitud de la transformada de Fourier o espectro de Fourier de  $f(x)$  y el ángulo de fase para una función bidimensional, quedan definidos respectivamente como:

$$F(u, v) = |F(u, v)| e^{-i\theta(u, v)}, \quad (13)$$

con magnitud:

$$|F(u, v)| = \sqrt{\text{Re}(F(u, v))^2 + \text{Im}((u, v))^2}, \quad (14)$$

y fase

$$\theta(u, v) = \tan^{-1} \left[ \frac{\text{Im}(F(u, v))}{\text{Re}((u, v))} \right]. \quad (15)$$

## 2.6 Propiedades de la transformada de Fourier

La transformada de Fourier,  $\mathfrak{F}$ , cuenta con varias propiedades. A continuación se presentan algunas de las más importantes en el área de procesamiento de imágenes (Hsu, 1998, p. González y Woods, 2002, p.194).

### 2.6.1 Linealidad

La transformada de Fourier de la suma de dos funciones lineales es la suma de la transformada de cada función individual:

$$\mathfrak{F}\{af_1(x, y) + bf_2(x, y)\} = a\mathfrak{F}\{f_1(x, y)\} + b\mathfrak{F}\{f_2(x, y)\}, \quad (16)$$

mediante esta propiedad las funciones individuales no son afectadas por la transformada.

La transformada de Fourier y su inversa tienen la propiedad distributiva respecto a la suma pero no para el producto,

$$\mathfrak{F}\{f_1(x, y)f_2(x, y)\} \neq \mathfrak{F}\{f_1(x, y)\}\mathfrak{F}\{f_2(x, y)\}. \quad (17)$$

### 2.6.2 Desplazamiento en el dominio del espacio

El desplazamiento de una función en el dominio del espacio es equivalente a un desplazamiento de fase lineal en el dominio de la frecuencia, es decir que el contenido de la frecuencia es invariante y sólo se altera la fase del espectro,

$$\mathfrak{F}\{f(x - x_0, y - y_0)\} = F(u, v)e^{-i2\pi(ux_0 + vy_0)}, \quad (18)$$

donde  $x_0$  y  $y_0$  representan constantes reales.

Es importante considerar que un desplazamiento en la función  $f(x, y)$  no provocará un cambio en la magnitud de su transformada de Fourier,

$$\left| F(u, v) e^{-i2\pi(ux_0 + vy_0)} \right| = |F(u, v)|. \quad (19)$$

### 2.6.3 Desplazamiento en el dominio de la frecuencia

Una función  $F(u, v)$  puede ser desplazada por las variables  $u_0$  y  $v_0$  del dominio de la frecuencia al dominio del espacio mediante la transformada inversa de Fourier:

$$\mathfrak{F}^{-1} \{ F(u - u_0, v - v_0) \} = f(x, y) e^{i2\pi(xu_0 + yv_0)}. \quad (20)$$

### 2.6.4 Simetría

Si una función  $F(u, v)$  es real, el módulo de su transformada de Fourier presenta simetría:

$$|F(u, v)| = |F(-u, -v)|. \quad (21)$$

### 2.6.5 Rotación

La transformada de Fourier de una función en el dominio de la frecuencia está representada por una parte real y una imaginaria, de esta manera también puede ser representada en forma polar al introducir las coordenadas polares:  $x = r \cos \theta$ ;  $y = r \sin \theta$ ;  $u = \omega \cos \phi$ ;  $v = \omega \sin \phi$ , entonces las funciones  $f(x, y)$  y  $F(u, v)$  serán  $f(r, \theta)$  y  $F(\omega, \phi)$ , de esta manera se cumple:

$$f(r, \theta + \theta_0) = F(\omega, \phi + \theta_0), \quad (22)$$

si la función  $f(x, y)$  es rotada a un determinado ángulo  $\theta_0$ , la transformada de Fourier también presentará una rotación del mismo ángulo. Esta propiedad se puede aplicar también a la inversa, si la transformada es rotada a un determinado ángulo la transformada inversa se rotará a ese mismo ángulo.

### 2.6.6 Escalamiento

La expansión de una función en el dominio espacial presenta una contracción en el dominio de las frecuencias. Si  $\mathfrak{F}\{f(x, y)\} = F(u, v)$  entonces:

$$\mathfrak{F}\{f(ax, by)\} = \frac{1}{|ab|} F\left(\frac{u}{a}, \frac{v}{b}\right), \quad (23)$$

donde  $a, b$  son números reales, ambos distintos de cero. Si la función en el dominio del espacio se contrae, en el dominio de la frecuencia se dilata y viceversa.

### 2.6.7 Teorema de Parseval

El teorema de Parseval establece que la energía de una señal real calculada en el dominio del espacio, es numéricamente igual a la energía calculada en el dominio de la frecuencia, por tanto al aplicar la transformada de Fourier la energía de la señal se conserva. Esto es expresado de la forma:

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} |f(x, y)|^2 dx dy = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} |F(u, v)|^2 du dv. \quad (24)$$

### 2.6.8 Teorema de la convolución

La convolución,  $\odot$ , de dos funciones está definida por:

$$f(x, y) \odot g(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x', y') g(x - x', y - y') dx' dy'. \quad (25)$$

La convolución en cierta manera representa la magnitud en que se superpone  $f(x, y)$  y una versión trasladada e invertida de  $g(x, y)$ .

Si  $F(u, v)$  y  $G(u, v)$  son las transformadas de Fourier de  $f(x, y)$  y  $g(x, y)$  respectivamente, entonces la transformada de Fourier de la convolución  $f(x, y) \odot g(x, y)$  será igual a  $F(u, v)G(u, v)$ , ya que el teorema de convolución establece que la transformada de Fourier de una convolución en un dominio es el producto en el otro dominio. El teorema de convolución se puede expresar por las ecuaciones:

$$\mathfrak{F}\{f(x, y) \odot g(x, y)\} = F(u, v)G(u, v), \quad (26)$$

$$\mathfrak{F}\{f(x, y)g(x, y)\} = F(u, v) \odot G(u, v). \quad (27)$$

Para calcular la convolución de dos funciones, la transformada de Fourier se usa de la siguiente manera:

$$f(x, y) \odot g(x, y) = \mathfrak{F}^{-1}\{F(u, v)G(u, v)\}. \quad (28)$$

La ecuación anterior describe la convolución de funciones continuas, para el caso de funciones discretas de tamaño  $M \times N$  la convolución se define como:

$$f(x, y) \odot g(x, y) = \sum_{x'=0}^{M-1} \sum_{y'=0}^{N-1} f(x', y')g(x - x', y - y'), \quad (29)$$

donde  $x' = 0, 1, 2, 3, \dots, M - 1$  y  $y' = 0, 1, 2, 3, \dots, N - 1$ .

### 2.6.9 Teorema de la correlación

La correlación de dos funciones reales  $f(x, y)$  y  $g(x, y)$  se define por la doble integral:

$$f(x, y) \otimes g(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x', y')g(x + x', y + y')dx'dy', \quad (30)$$

donde el símbolo  $\otimes$  denota la correlación.



Para el caso de funciones complejas se debe utilizar el complejo conjugado de alguna de las funciones:

$$f(x, y) \otimes g(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x', y') g^*(x + x', y + y') dx' dy', \quad (31)$$

el símbolo \* se utiliza para indicar el complejo conjugado, en este caso el complejo conjugado de  $g$  es  $g^*$ .

El teorema de correlación se expresa con las siguientes ecuaciones:

$$\mathfrak{F}\{f(x, y) \otimes g(x, y)\} = F(u, v)G^*(u, v), \quad (32)$$

$$\mathfrak{F}\{f(x, y)g^*(x, y)\} = F(u, v) \otimes G(u, v). \quad (33)$$

La correlación de dos señales se obtiene mediante la transformada de Fourier de la siguiente manera:

$$f(x, y) \otimes g(x, y) = \mathfrak{F}^{-1}\{F(u, v)G^*(u, v)\}. \quad (34)$$

Para el caso de dos funciones discretas, la correlación está dada de la siguiente manera:

$$f(x, y) \otimes g(x, y) = \sum_{x'=0}^{M-1} \sum_{y'=0}^{N-1} f(x', y')g(x + x', y + y'), \quad (35)$$

donde  $x' = 0, 1, 2, 3, \dots, M - 1$  y  $y' = 0, 1, 2, 3, \dots, N - 1$ .

## Capítulo 3.


---

### Metodología

#### 3.1 Banco de imágenes

El banco de imágenes se construyó con imágenes proporcionadas por el Departamento de Dermatología del Centenario Hospital Miguel Hidalgo de la ciudad de Aguascalientes y del Instituto Nacional de Cancerología (INcan) de la Ciudad de México. Estas imágenes fueron clasificadas previamente por médicos especialistas de acuerdo al tipo de cáncer: carcinoma basocelular, carcinoma epidermoide y melanoma. También se obtuvieron imágenes de manchas de piel no cancerígenas para realizar la comparación de resultados, después se hizo una examinación histopatológica.

En algunas imágenes se seleccionó de forma manual sólo la mancha para ser analizada como se muestra en la figura 9, ya que sólo es necesario la información de dicha mancha. El tamaño de las imágenes es variado, además se trabajó con imágenes en formato jpg, sin embargo también se puede trabajar con otros formatos.



**Figura 9.** Imágenes de cáncer de piel.

### 3.2 Análisis multiespectral

Una señal puede representar diferentes tipos de información (voz, datos, imágenes, vídeos) y cada señal está formada por una serie de frecuencias, de esta manera el espectro de la señal contiene la distribución de amplitudes de cada frecuencia y su intensidad.

Una imagen está constituida por un conjunto de datos de intensidad en el dominio espacial y se puede representar por la función multiespectral  $f_w^{\lambda_c}(x, y)$ , donde  $(x, y)$  son las coordenadas de cada pixel,  $\lambda_c = \{\lambda_R, \lambda_G, \lambda_B\}$  que representa los canales rojo (R), verde (G) y azul (B) del modelo de color RGB de la imagen digital con un rango de  $[0, 255]$  y  $w$  representa el número de imagen.

El banco de imágenes contiene las funciones  $f_1^{\lambda_c}, f_2^{\lambda_c}, f_3^{\lambda_c}, \dots, f_w^{\lambda_c}$  y cada una de estas funciones representa una imagen de tamaño  $M \times N$  pixeles, donde  $x = 1, \dots, M$ ,  $y = 1, \dots, N$ .

Cada imagen  $f_w^{\lambda_c}(x, y)$  puede separarse en sus respectivos canales RGB, de esta manera se obtienen tres matrices de intensidad  $f_w^{\lambda_R}(x, y)$ ,  $f_w^{\lambda_G}(x, y)$  y  $f_w^{\lambda_B}(x, y)$ .

Para determinar el canal sobre el cual se va a trabajar es necesario determinar el perfil de intensidad en cada uno de los canales, dicho perfil se obtiene al convertir un segmento de la imagen a una señal unidimensional para analizar sus cambios.

La matriz de intensidad de cada canal es analizada tomando un conjunto de vectores de perfil de intensidad  $\{\xi_q^{\lambda_c}\}_w$ , donde el renglón  $q = 1, \dots, Q$  y  $\{\xi_q^{\lambda_c}\}_w \in f_w^{\lambda_c}(x, y)$ , por lo tanto  $\{\xi_q^{\lambda_c}\}_w$  se puede definir como:

$$\{\xi_q^{\lambda_c}\}_w = f_w^{\lambda_c}(x, \zeta_{v_t}), \text{ para } \zeta_{v_t} = -\frac{Q}{2} + \left\lfloor \frac{N}{2} \right\rfloor, \dots, \frac{Q}{2} + \left\lfloor \frac{N}{2} \right\rfloor, \quad (36)$$

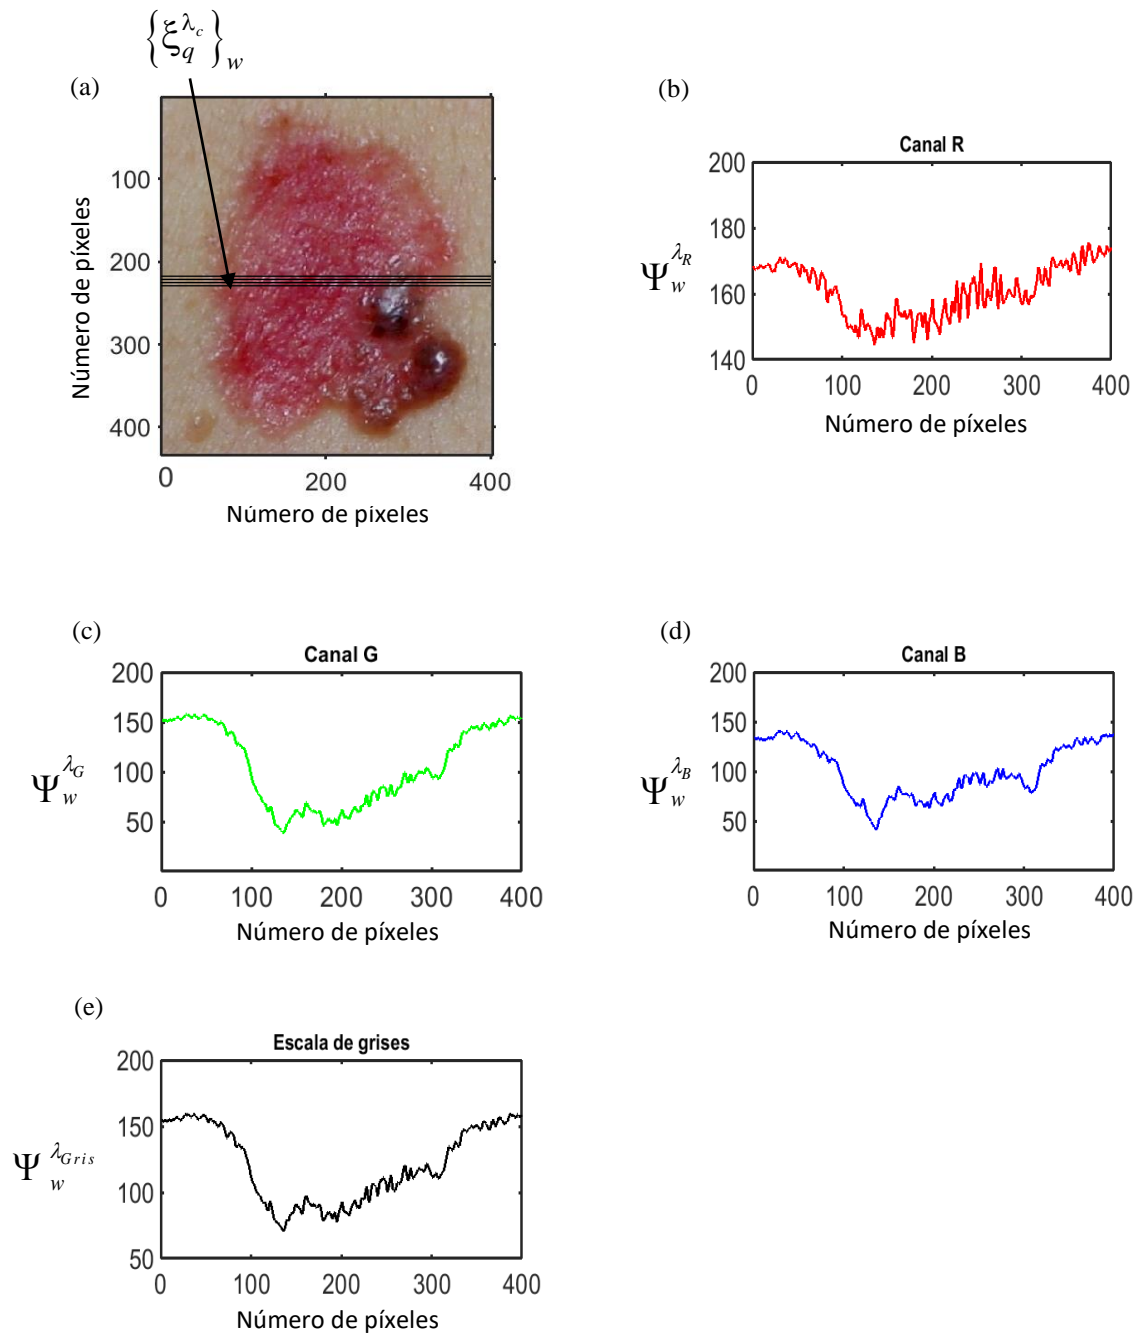
donde  $Q$  es el número de vectores, y  $x = 1, \dots, M$ .

Usando la ecuación (36) el vector de valores medios  $\left(\Psi_w^{\lambda_c}\right)_k$  de todos los vectores del perfil de intensidad en cada canal es calculado por:

$$\left(\Psi_w^{\lambda_c}\right)_k = \frac{\sum_k \{\xi_q^{\lambda_c}\}_w^k}{Q}, \quad (37)$$

donde  $\Psi_w^{\lambda_c} \in \mathbb{R}$  y  $k=1, \dots, M$ .

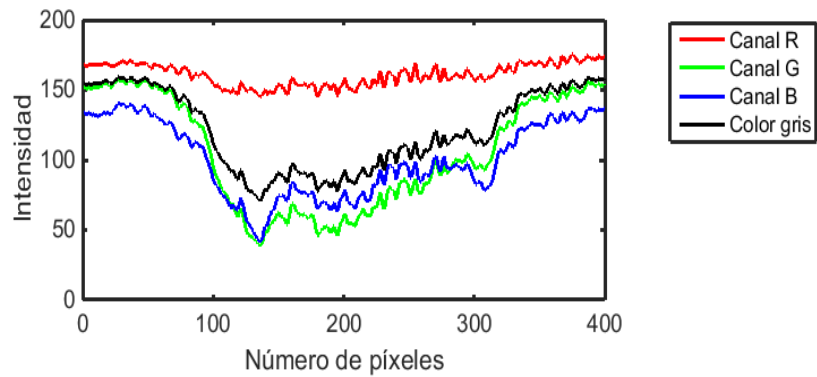
Para este estudio se tomó  $Q = 30$  para el análisis de todas las imágenes. La figura 10(a) muestra el conjunto de vectores de perfil de intensidad  $\{\xi_q^{\lambda_c}\}_w$  con los gráficos calculados usando la ecuación (37), en esta figura también se muestran los gráficos obtenidos con la medición de patrones de intensidad para cada canal  $\Psi_w^{\lambda_R}$ ,  $\Psi_w^{\lambda_G}$ ,  $\Psi_w^{\lambda_B}$  y  $\Psi_w^{\lambda_{Gris}}$  respectivamente. El eje de las  $x$  representa la distancia a lo largo del perfil.



**Figura 10.** Perfiles de intensidad, (a) conjunto de vectores de intensidad, (b) valores medios de los perfiles de intensidad del canal rojo, (c) valores medios del perfil de intensidad del canal verde, (d) valores medios del perfil de intensidad del canal azul y (e) valores medios del perfil de intensidad de la escala de gris.

Se obtuvieron los perfiles de intensidad con el objetivo de conocer el canal que proporciona mayor información.

La figura 11 muestra los perfiles de intensidad  $\Psi_w^{\lambda_R}$ ,  $\Psi_w^{\lambda_G}$ ,  $\Psi_w^{\lambda_B}$  y  $\Psi_w^{\lambda_{Gris}}$  de cada canal de la imagen 10(a). En esta imagen se puede observar una pequeña diferencia, entre los perfiles de cada canal, sin embargo los resultados obtenidos después de aplicar la metodología no presentan una diferencia significativa al 95.4%, por lo tanto cualquier canal incluyendo la imagen en escala de grises puede utilizarse.



**Figura 11.** Perfiles de intensidad de todos los canales y escala de gris.


### 3.3 Segmentación de imágenes

La segmentación de la imagen es una de las etapas más importantes en cualquier proceso que se lleve a cabo para analizar una imagen. Su objetivo es dividir una imagen de entrada en regiones o categorías de acuerdo a las objetos que la constituyen, esta etapa es una de las tareas más difíciles, sin embargo se han desarrollado diversas técnicas con el objetivo de tener una mejora en la segmentación. Debido a su complejidad, las imágenes biológicas han presentado dificultades para obtener una buena segmentación (Uchida, 2013). Para este trabajo la segmentación se basa en considerar una sola región, es decir la imagen es dividida en objeto y fondo, el objeto se refiere a la región de interés que contiene la lesión de la piel y el fondo contiene la piel sana.

Por lo general los algoritmos de segmentación se basan en la discontinuidad identificando los cambios bruscos en el nivel de gris para obtener los bordes en la imagen, también se basan

en la similitud donde se aplican diversas técnicas entre las cuales se encuentran: la segmentación por umbral, el crecimiento de regiones y técnicas de división y fusión.

En este trabajo se utilizó la técnica de umbralización. Esta técnica consiste en lo siguiente, primero se convierte la imagen a escala de grises, luego se aplica un valor umbral para obtener la imagen binarizada que toma el nombre de máscara binaria. La figura 12 muestra las imágenes del proceso de segmentación.



**Figura 12.** Segmentación (a) imagen original, (b) imagen en escala de gris y (c) máscara binaria.

La función de máscara binaria  $I_{mask}(x,y)$  para obtener la imagen binarizada es expresada por:

$$I_{Mask}(x,y) = \begin{cases} 1, & \text{si } f_w^{\lambda_{Gr\acute{e}s}}(x,y) > T \\ 0, & \text{si } f_w^{\lambda_{Gr\acute{e}s}}(x,y) \leq T \end{cases} \quad (38)$$

donde  $T$  representa el valor umbral. Al aplicar este método la imagen en escala de grises quedará binarizada, por lo tanto todos los valores mayores que  $T$  tomarán el valor de 1 y todos los valores menores o iguales que  $T$  tomarán el valor de 0. Este método es uno de los más utilizados, además para determinar el valor umbral se aplicó el método Otsu, que consiste en obtener el umbral óptimo, ecuación (39), bajo el criterio de la máxima varianza,  $\sigma^2$ , entre el fondo (piel sana) y el objeto de interés (para este caso la lesión de la piel), de tal modo que:

$$T = \max(\sigma^2). \quad (39)$$

En una imagen la lesión de la piel es la región de interés que será analizada, la cual se obtiene mediante el área total de la máscara binaria y se calcula de la siguiente manera:

$$A_{mask} = \sum_1^M \sum_1^N I_{Mask}(x, y). \quad (40)$$

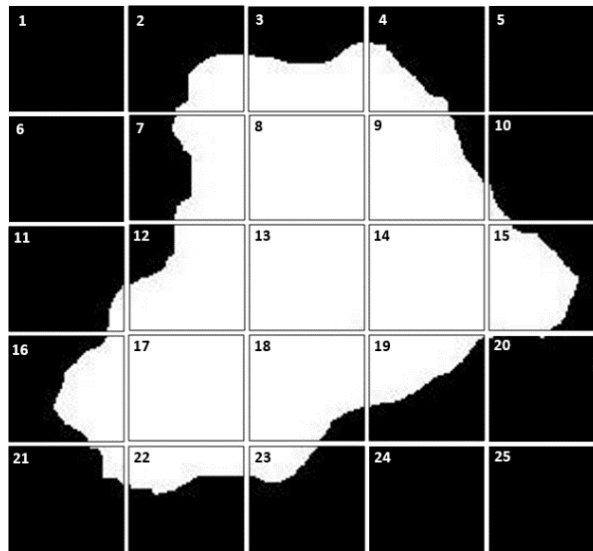
Como se mencionó anteriormente se puede tomar cualquier canal para hacer el análisis. Los datos de la matriz de intensidad del canal seleccionado se multiplican punto a punto por la función de máscara binaria  $I_{Mask}(x, y)$ , para obtener la función:

$$I_w^{\lambda_c}(x, y) = f_w^{\lambda_c}(x, y) \times I_{Mask}(x, y), \quad (41)$$

la función  $I_w^{\lambda_c}(x, y)$  contiene la información necesaria de la lesión que será analizada.

### 3.4 Sub-imágenes


Cada una de las imágenes de la máscara binaria fue dividida en 25 sub-imágenes (o pueden ser más) de igual dimensión para obtener la función  $A_{Mask_j}$ , que representa el área respectiva de cada sub-imagen  $j = 1, 2, 3, \dots, 25$ , en la figura 13 se puede observar el resultado de sub-imágenes.



**Figura 13.** Sub-imágenes de la máscara binaria.



De igual manera la imagen de la función  $I_w^{\lambda_c}(x, y)$  fue dividida en 25 sub-imágenes. Como se muestra en la figura 14 y cada sub-imagen es representada por su función correspondiente  $I_{w_j}^{\lambda_c}(x, y)$ .




**Figura 14.** Sub-imágenes  $I_{w_j}^{\lambda_c}(x, y)$ ,  $j = 1, 2, 3, \dots, 25$ .

El siguiente paso consiste en seleccionar aquellas sub-imágenes  $I_{w_j}^{\lambda_c}(x, y)$  que cumplan con la condición:

$$A_{Mask_j} \geq \frac{1}{3} [I_{Mask_j}(x, y)], \quad (42)$$

con el fin de seleccionar sólo aquellas imágenes que contengan información mayor o igual a un tercio del total del área de la sub-imagen. En la figura 15 se muestran las sub-imágenes que cumplen con esta condición.



**Figura 15.** Sub-imágenes  $I_{w_j}^{\lambda_c}(x, y)$  que contienen información mayor o igual a un tercio de su área.

### 3.5 Filtros digitales

El término filtro hace referencia a un proceso o dispositivo que modifica el espectro o contenido de frecuencias de una señal, también puede permitir o impedir el paso de cierta información de acuerdo a su entrada. El desarrollo de filtros digitales tomó gran seriedad a mediados de los años 1960s. Un filtro digital se refiere a un algoritmo que es implementado en hardware o software, además, siendo de gran importancia en el procesamiento digital de señales. Por lo que se ha desarrollado una gran cantidad de filtros con diferentes variantes, en el desarrollo del presente trabajo se hace uso principalmente de filtros bajo el dominio de la frecuencia tales como el clásico, inverso y no lineal ley-k.

### 3.6 Filtros en el dominio de la frecuencia

Un filtro se puede describir como una operación matemática, por la cual una señal de entrada es modificada en la señal de salida, de manera que las amplitudes en frecuencia son cambiadas, además impide o permite el paso de ciertas frecuencias, atenuándolas o

resaltándolas, también se aplica para restaurar una señal. Por otro lado permite caracterizar una señal de entrada y adaptarla a los cambios en las características de la señal.

Los filtros permiten extraer información de interés en una imagen, la metodología presentada en este trabajo está basada en los filtros clásico, inverso y no lineal ley k, los cuales permiten trabajar sobre el dominio de la frecuencia.

### 3.7 Filtro clásico acoplado (CMF)

Este filtro también es conocido como filtro complejo u holográfico, por sus siglas en inglés (Classical Matched Filter), fue propuesto por Vander Lugt en 1964, quien lo describió como una función compleja, por lo tanto para este trabajo se aplicó de la siguiente manera:

$$I(u, v)_{CMF} = |I_{w_j}^{\lambda_c}(u, v)| \exp \left[ i\varphi_{w_j}(u, v) \right], \quad (43)$$

donde  $(u, v)$  son variables en frecuencia,  $|I_{w_j}^{\lambda_c}(u, v)|$  representa el módulo de la transformada de Fourier de la  $j$ -ésima sub-imagen y  $\varphi_{w_j}(u, v)$  es la fase de la transformada de Fourier de la  $j$ -ésima sub-imagen.

### 3.8 Filtro inverso (IF)

El filtro inverso (Abdul, 1990; Kumar y Hassebrook, 1990) se aplicó de la siguiente manera:

$$I(u, v)_{IF} = \frac{\exp \left[ -i\varphi_{w_j}(u, v) \right]}{|I_{w_j}^{\lambda_c}(u, v)|}. \quad (44)$$

### 3.9 Filtro no lineal ley k

Este filtro se caracteriza por generar una salida no lineal de la función que se tiene de entrada (Kumar y Hassebrook, 1990), por lo tanto se expresa se aplicó de la siguiente manera:

$$I(u, v)_{NLF} = |I_{w_j}^{\lambda_c}(u, v)|^k \exp\left[i\phi_{w_j}(u, v)\right], \quad (45)$$

donde  $k$  es el factor de no linealidad que toma valores  $0 < k < 1$ . En este caso para el presente trabajo se tomó el factor de no linealidad de  $k = 0.1$ .

### 3.10 Índice espectral

La densidad espectral  $SSF$  se define como una función en el dominio de las frecuencias que contiene las propiedades espectrales de la función  $F_{w_j}^{\lambda_c}(u, v)$ , esta densidad se obtiene al aplicar algún filtro a la  $j$ -ésima sub-imagen, por lo tanto el índice espectral se puede describir como una medición cuantitativa de patrones complejos (Bueno-Ibarra et al., 2010).

Para obtener el valor del índice espectral es necesario antes binarizar la densidad espectral mediante las condiciones:

$$\begin{aligned} SSF_1(F_{w_j}^{\lambda_c}(u, v)) &= \begin{cases} 1, & \text{Si } Re(F_{w_j}^{\lambda_c}(u, v)) \geq 0 \\ 0, & \text{cualquier otro valor} \end{cases}, \\ SSF_2(F_{w_j}^{\lambda_c}(u, v)) &= \begin{cases} 1, & \text{Si } Re(F_{w_j}^{\lambda_c}(u, v)) < 0 \\ 0, & \text{cualquier otro valor} \end{cases}, \\ SSF_3(F_{w_j}^{\lambda_c}(u, v)) &= \begin{cases} 1, & \text{Si } Im(F_{w_j}^{\lambda_c}(u, v)) \geq 0 \\ 0, & \text{cualquier otro valor} \end{cases}, \\ SSF_4(F_{w_j}^{\lambda_c}(u, v)) &= \begin{cases} 1, & \text{Si } Im(F_{w_j}^{\lambda_c}(u, v)) < 0 \\ 0, & \text{cualquier otro valor} \end{cases}, \end{aligned} \quad (46)$$

donde  $Re(F_{w_j}^{\lambda_c}(u, v))$ , es la parte real y  $Im(F_{w_j}^{\lambda_c}(u, v))$  es la parte imaginaria de la  $j$ -ésima sub-imagen. Estas condiciones son aplicadas para determinar cual es la que proporciona mejores resultados.

El índice espectral de cada sub-imagen se obtiene mediante la razón de la suma de valores unitarios presentes en la ecuación (46) y la suma de valores unitarios de la máscara binaria presentes en la ecuación (40) , el cual está definido por:

$$i_m^{SSF} = \left\{ \frac{SSF_n(F_{w_m}^{\lambda_c}(u, v))}{A_{Mask_j}} \right\}. \quad (47)$$

donde  $m$  es el numero de cada sub-imagen y  $n$  representa la condición aplicada para binarizar la densidad espectral.

Finalmente el índice espectral de la imagen analizada se obtiene mediante la media de los índices espectrales de cada sub-imagen, el cual se calcula de la siguiente manera:

$$\bar{i}^{SSF} = \frac{\sum_1^m i_m^{SSF}}{m}. \quad (48)$$

La figura 16 muestra el diagrama de bloques de la metodología desarrollada para obtener el índice espectral de una imagen. Esta metodología es explicada por los siguientes pasos:

Se toma la imagen a analizar del banco de imágenes, la cual es representada por la función  $f_w^\lambda(x, y)$ ; 1) Esta imagen es segmentada usando el método del umbral para obtener la función de máscara binaria, esta función contiene al área de la lesión a ser analizada; 2) La imagen se divide en los canales RGB:  $f_w^{\lambda_R}(x, y)$ ,  $f_w^{\lambda_G}(x, y)$ ,  $f_w^{\lambda_B}(x, y)$  y color gris; 3) Después se selecciona arbitrariamente un canal de color o la escala de grises para trabajar, este canal es multiplicado punto a punto por la máscara binaria, de esta manera se obtiene la función  $I_w^{\lambda_c}(x, y)$ ; 4) La imagen de intensidad obtenida se divide en 25 sub-imágenes; 5) Cada sub-imagen es analizada, si la información contenida en el área de la lesión de esa sub-imagen es mayor o igual a un tercio del total de su área correspondiente se aplica el siguiente paso,

si esta condición no se cumple se analiza la siguiente sub-imagen bajo la misma condición, el siguiente paso se aplica para aquellas imágenes que si cumplen con esta condición; 6) Se toma la sub-imagen; 7) A esta sub-imagen se le aplica el filtro (ya sea el clásico, inverso o no lineal ley-k, debido a que el resultado obtenido por cualquiera de los tres difiere en diezmilésimas) y se obtiene la función en el dominio de las frecuencias formada por una parte real y una parte imaginaria; 8) Estas frecuencias son binarizadas para obtener la densidad espectral, esto se realiza tomando una condición de la ecuación 45, por ejemplo tomando la primer condición:

$$SSF_1(F_{w_j}^{\lambda_c}(u, v)) = \begin{cases} 1, & \text{Si } Re(F_{w_j}^{\lambda_c}(u, v)) \geq 0 \\ 0, & \text{cualquier otro valor} \end{cases},$$

para este caso se considera la parte real y todos los valores que sean mayores o iguales a cero toman el valor de uno, de lo contrario si son menores a cero toman el valor de cero; 9) Posteriormente se obtiene el índice espectral de esa sub-imagen, mediante la razón de la suma de todos los valores unitarios presentes en la densidad espectral binarizada, entre la suma de todos los valores unitarios presentes en la sub-máscara binaria correspondiente a esa sub-imagen; 10) Una vez que se analizan las sub-imágenes finalmente se obtiene el índice espectral de la imagen inicial, mediante la media de todos los índices de las sub-imágenes analizadas.

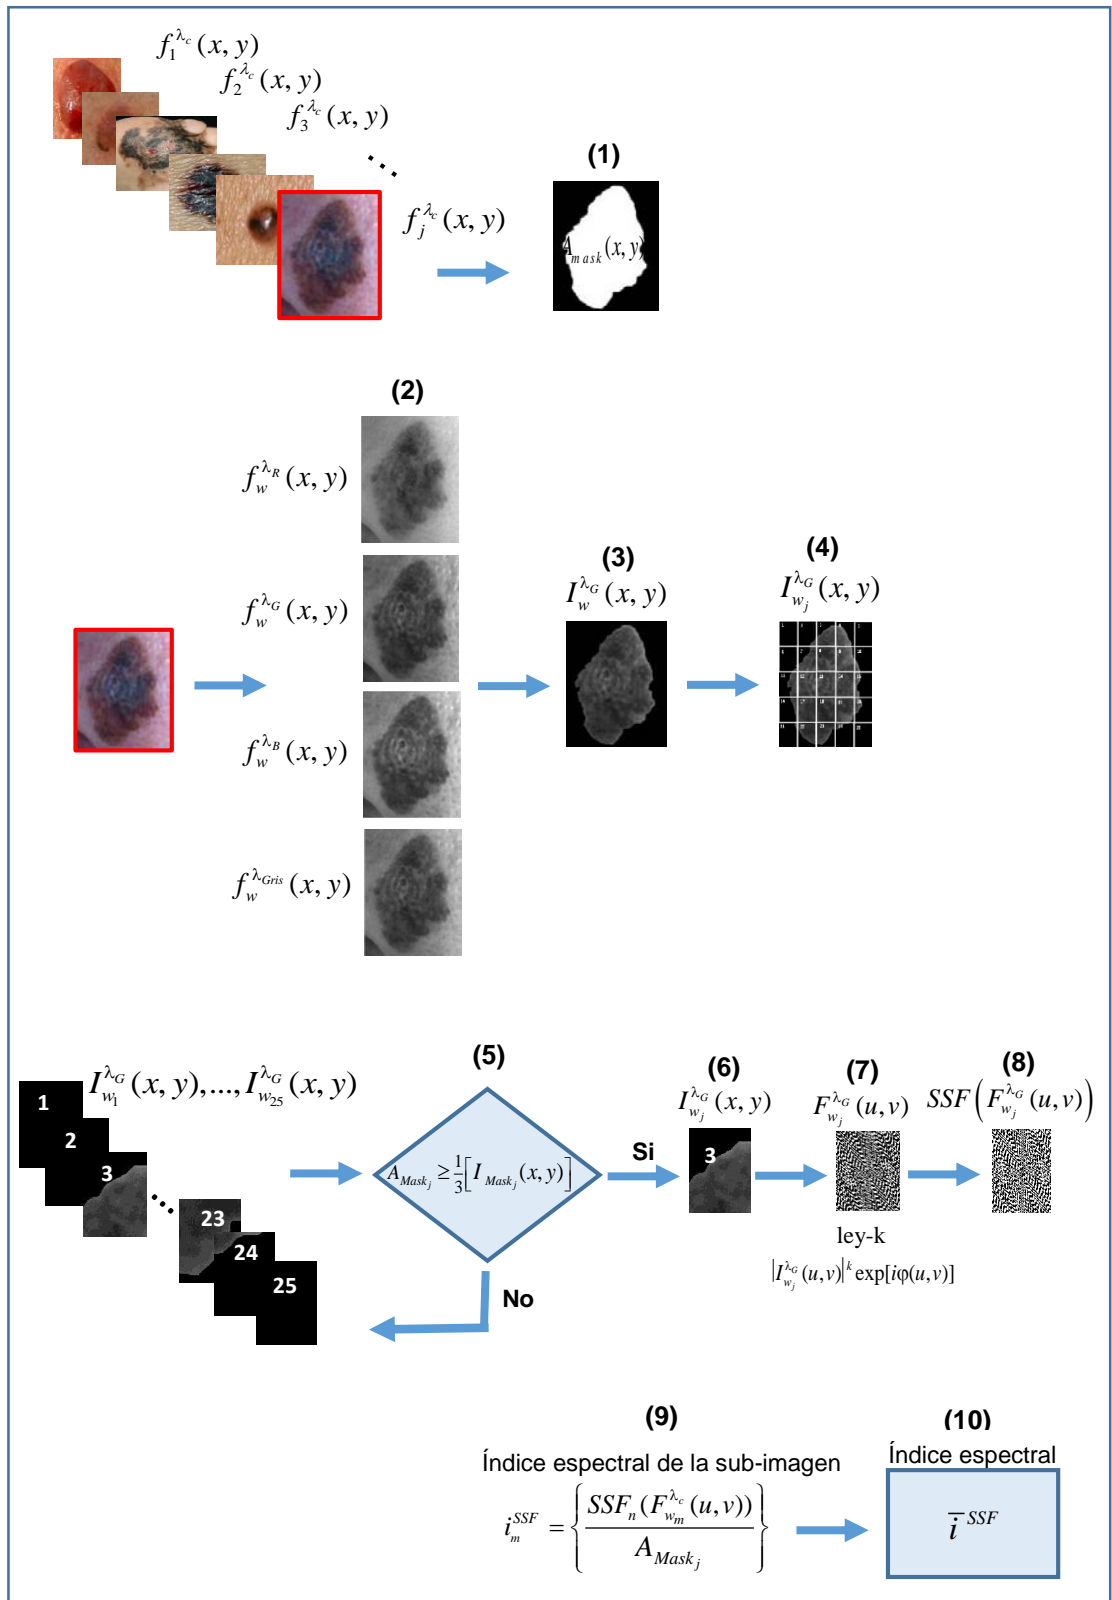


Figura 16. Diagrama de bloques para obtener el índice espectral de una imagen.

## Capítulo 4

---

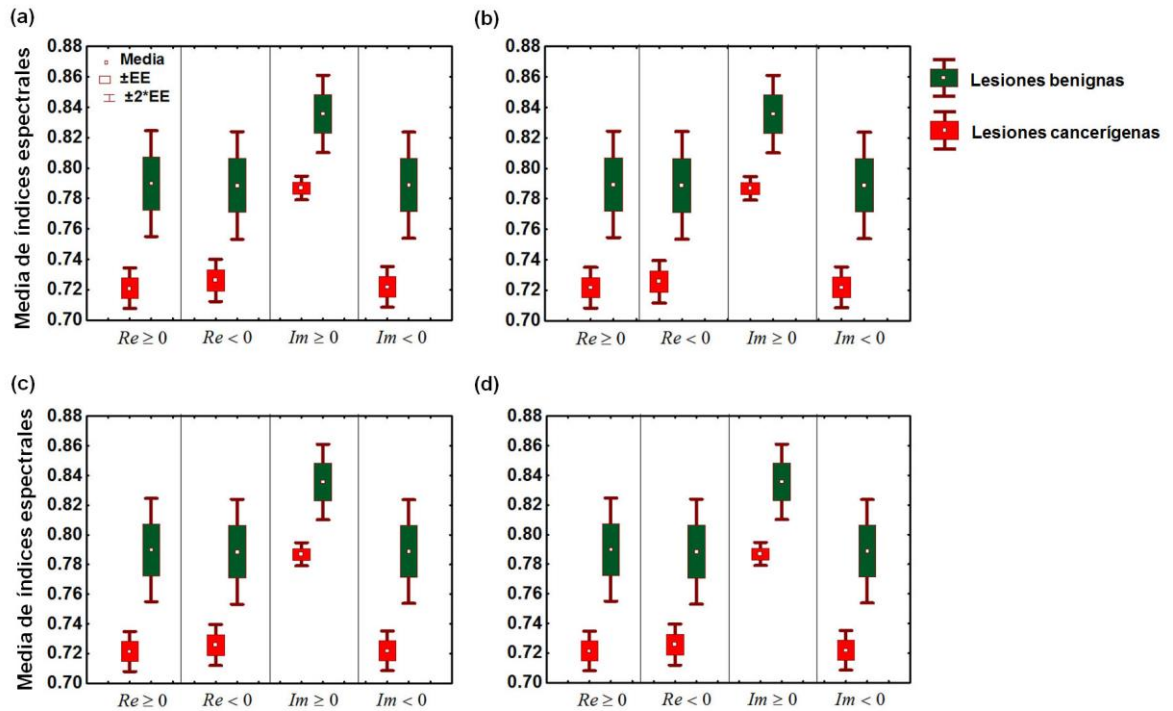
### Resultados

Esta metodología se aplicó a un conjunto de 332 imágenes dermatológicas en formato *jpg* proporcionadas por médicos especialistas en piel. Este conjunto de imágenes contiene tanto imágenes de cáncer de piel (260), como imágenes de lesiones benignas (72). Cada una de las imágenes presenta diferente resolución, ya que el tamaño y la localización de cada lesión varía de una persona a otra. Uno de los aspectos importantes es obtener la imagen bien enfocada al momento de capturarla, es decir enfocarla de forma manual al momento de obtenerla mediante una cámara o dispositivo de captura.

Se obtuvieron los intervalos de confianza de índices espectrales considerando las condiciones dadas por la ecuación 46 las cuales se aplicaron a cada canal de color y a cada uno de los filtros.

La figura 17 muestra los diagramas de cajas de los índices obtenidos, el eje de las  $x$  representa cada una de las condiciones aplicadas por la ecuación 46 y el eje de las  $y$  representa la media de los valores de los índices espectrales con dos errores estándar ( $\pm 2EE$ ), para el filtro no lineal ley-k. Las cajas en color rojo representan las imágenes cancerígenas que incluye los tres tipos de cáncer: carcinoma basocelular, carcinoma epidermoide y melanoma y las cajas de color verde representan las lesiones benignas. Estos diagramas también se obtuvieron para el filtro clásico e inverso, los cuales mostraron resultados muy similares en todos los casos.





**Figura 17.** Clasificación de lesiones (benignas y malignas). Diagrama de cajas de índices espectrales mediante el filtro Ley-k. (a) Canal rojo, (b) canal verde, (c) canal azul y (d) escala de grises.

La tabla 1 presenta los intervalos de las medias de los índices espectrales obtenidos mediante un análisis estadístico (media  $\pm 2EE$ ), aplicando el filtro no lineal ley-k. Se puede apreciar que en cada canal hay una clara diferencia entre los intervalos obtenidos para imágenes de cáncer de piel y lesiones benignas, en base a estos resultados se observa que las imágenes de cáncer de piel pueden ser localizadas en una franja de valores bien definida. Los filtros clásico e inverso también fueron analizados obteniendo los mismos valores. Esto se debe a las condiciones aplicadas (de la ecuación 46) al momento de binarizar la densidad espectral en cada sub-imagen. Esta metodología presenta un nivel de confianza del 95.4%.

**Tabla 1. Intervalos obtenidos con el filtro no lineal ley-k  
(media  $\pm 2EE$ )**

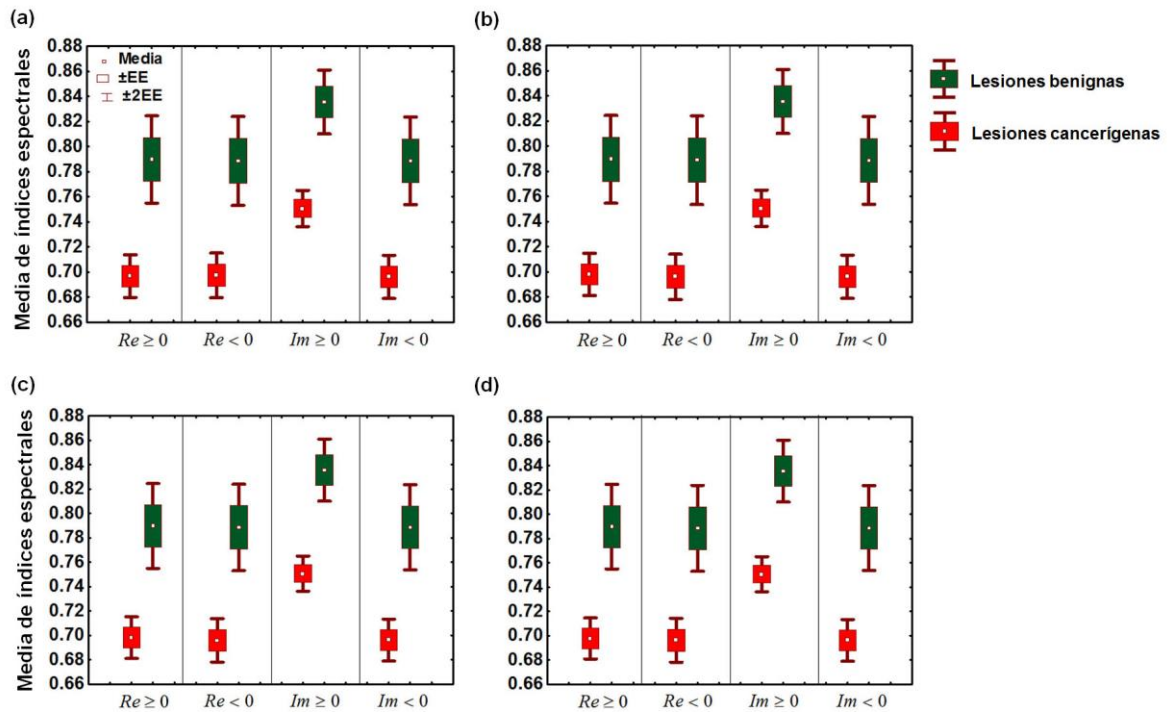
Condiciones		Intervalos para cáncer de piel	Intervalos para lesiones benignas
Canal R	$Re \geq 0$	0.7166 - 0.7393	0.7556 - 0.8239
Canal R	$Re < 0$	0.7195 - 0.7428	0.7538 - 0.8233
Canal R	$Im \geq 0$	0.7765 - 0.7897	0.8106 - 0.8605
Canal R	$Im < 0$	0.7167 - 0.7393	0.7544 - 0.8230
Canal G	$Re \geq 0$	0.7171 - 0.7397	0.7553 - 0.8237
Canal G	$Re < 0$	0.7190 - 0.7425	0.7541 - 0.8234
Canal G	$Im \geq 0$	0.7765 - 0.7897	0.8106 - 0.8605
Canal G	$Im < 0$	0.7167 - 0.7393	0.7544 - 0.8230
Canal B	$Re \geq 0$	0.7170 - 0.7399	0.7556 - 0.8239
Canal B	$Re < 0$	0.7190 - 0.7423	0.7538 - 0.8233
Canal B	$Im \geq 0$	0.7765 - 0.7897	0.8106 - 0.8605
Canal B	$Im < 0$	0.7167 - 0.7393	0.7544 - 0.8230
Escala de gris	$Re \geq 0$	0.7170 - 0.7397	0.7557 - 0.8240
Escala de gris	$Re < 0$	0.7191 - 0.7425	0.7537 - 0.8231
Escala de gris	$Im \geq 0$	0.7765 - 0.7897	0.8106 - 0.8605
Escala de gris	$Im < 0$	0.7167 - 0.7393	0.7544 - 0.8230

En la figura 16 los diagramas de cajas pertenecientes a las lesiones cancerígenas presentan la media de índices espectrales de lesiones cancerígenas, considerando los tres tipos de cáncer antes mencionados. La metodología también se aplicó analizando por separado las imágenes para cada tipo de cáncer de piel (carcinoma basocelular, carcinoma epidermoide y melanoma). De esta manera se obtuvieron diferentes intervalos de índices espectrales para cada grupo.

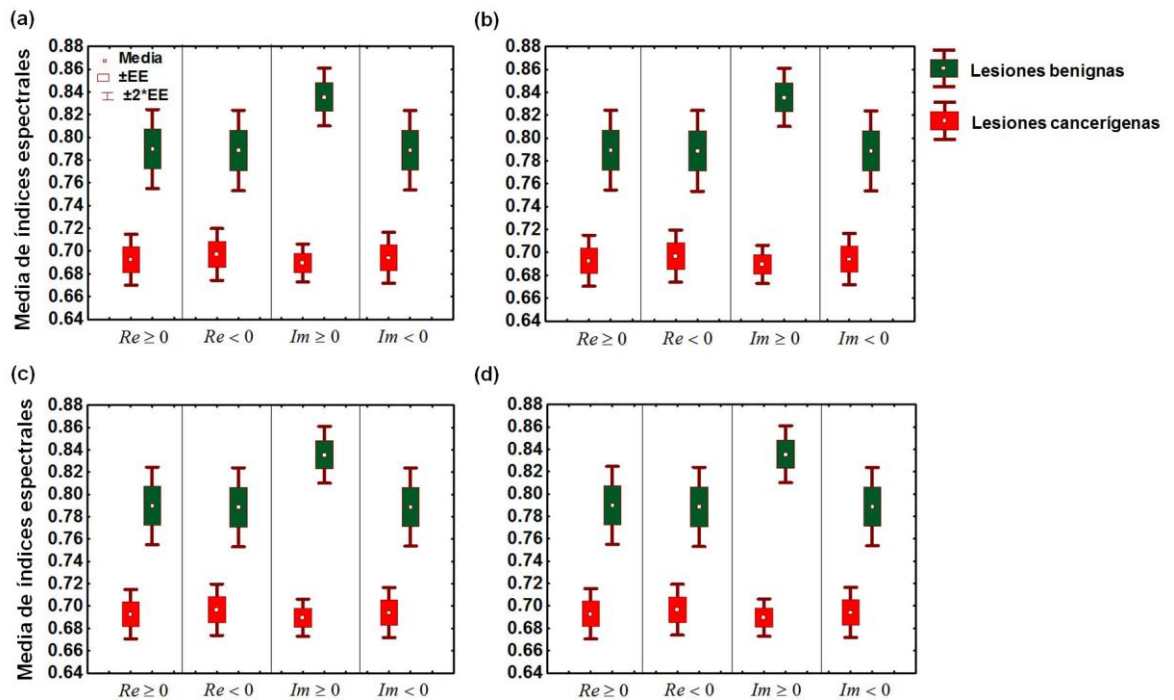
En la figura 17 se muestran los intervalos de índices espectrales obtenidos analizando imágenes pertenecientes al carcinoma basocelular, la figura 18 contiene los índices obtenidos para las imágenes referentes al carcinoma epidermoide y la figura 19 presenta los intervalos correspondientes a imágenes de melanoma. Estos resultados se obtuvieron aplicando el filtro ley-k con  $\pm$  dos errores estándar.

Para el presente estudio se tomaron 32 imágenes de carcinoma basocelular, 30 de carcinoma epidermoide y 198 de melanoma. En las figuras 18,19 y 20 nuevamente se puede observar que no existe traslape en los bigotes en cada una de las condiciones. Este proceso también se

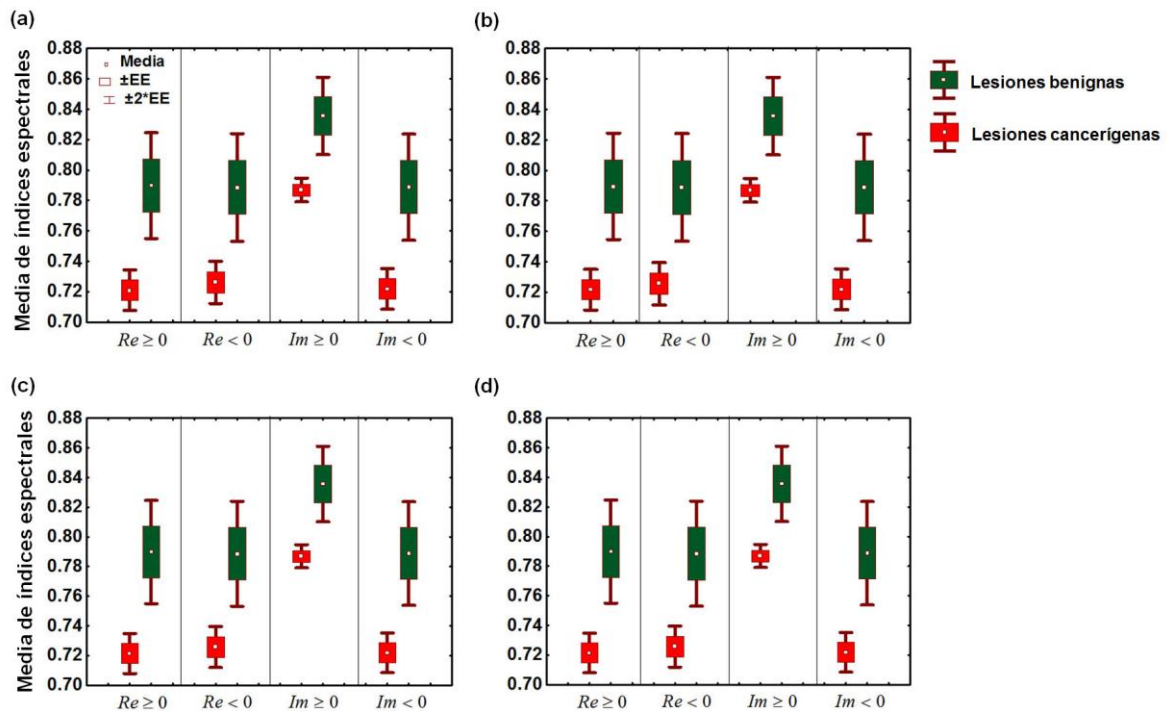
realizó aplicando los filtros clásico e inverso, obteniendo resultados muy similares en todos los casos. El rango de valores para los primeros dos tipos de cáncer es un poco más bajo al compararlo con el rango de valores para el melanoma. Por lo tanto, estas franjas bien definidas pueden ser útiles para determinar a qué tipo de cáncer de piel pertenece una lesión dada. La variabilidad biológica (barras de error) es mucho más grande en lesiones benignas que en lesiones malignas. Los resultados obtenidos en los tres canales y escala de gris son muy similares. En las tablas 2, 3 y 4 se puede observar la diferencia numérica.



**Figura 18.** Carcinoma basocelular. Diagrama de cajas de índices espectrales usando el filtro Ley-k: (a) canal rojo, (b) canal verde, (c) canal azul y (d) escala de grises.



**Figura 19.** Carcinoma epidermoide. Diagrama de cajas de índices espectrales usando el filtro Ley-k: (a) canal rojo, (b) canal verde, (c) canal azul y (d) escala de grises.



**Figura 20.** Melanoma. Diagrama de cajas de índices espectrales usando el filtro Ley-k: (a) canal rojo, (b) canal verde, (c) canal azul y (d) escala de grises.

**Tabla 2. Intervalos para el carcinoma basocelular  
(media  $\pm 2EE$ )**

Condiciones	Intervalos para carcinoma basocelular	Intervalos para lesiones benignas
Canal R $Re \geq 0$	0.6796 - 0.7137	0.7550 - 0.8246
Canal R $Re < 0$	0.6794 - 0.7151	0.7531 - 0.8240
Canal R $Im \geq 0$	0.7361 - 0.7651	0.8101 - 0.8611
Canal R $Im < 0$	0.6788 - 0.7133	0.7537 - 0.8237
Canal G $Re \geq 0$	0.6811 - 0.7148	0.7546 - 0.8244
Canal G $Re < 0$	0.6779 - 0.7140	0.7534 - 0.8242
Canal G $Im \geq 0$	0.7361 - 0.7651	0.8101 - 0.8611
Canal G $Im < 0$	0.6788 - 0.7133	0.7537 - 0.8237
Canal B $Re \geq 0$	0.6810 - 0.7152	0.7549 - 0.8246
Canal B $Re < 0$	0.6780 - 0.7136	0.7531 - 0.8240
Canal B $Im \geq 0$	0.7361 - 0.7651	0.8101 - 0.8611
Canal B $Im < 0$	0.6788 - 0.7133	0.7537 - 0.8237
Escala de gris $Re \geq 0$	0.6808 - 0.7146	0.7550 - 0.8247
Escala de gris $Re < 0$	0.6781 - 0.7143	0.7530 - 0.8239
Escala de gris $Im \geq 0$	0.7361 - 0.7651	0.8101 - 0.8611
Escala de gris $Im < 0$	0.6788 - 0.7133	0.7537 - 0.8237

**Tabla 3. Intervalos para el carcinoma epidermoide  
(media  $\pm 2EE$ )**

Condiciones	Intervalos para carcinoma epidermoide	Intervalos para lesiones benignas
Canal R $Re \geq 0$	0.6705 - 0.7143	0.7556 - 0.8239
Canal R $Re < 0$	0.6747 - 0.7194	0.7538 - 0.8233
Canal R $Im \geq 0$	0.6732 - 0.7058	0.8106 - 0.8605
Canal R $Im < 0$	0.6722 - 0.7162	0.7544 - 0.8230
Canal G $Re \geq 0$	0.6708 - 0.7146	0.7553 - 0.8237
Canal G $Re < 0$	0.6744 - 0.7191	0.7541 - 0.8234
Canal G $Im \geq 0$	0.6732 - 0.7058	0.8106 - 0.8605
Canal G $Im < 0$	0.6722 - 0.7162	0.7544 - 0.8230
Canal B $Re \geq 0$	0.6710 - 0.7145	0.7556 - 0.8239
Canal B $Re < 0$	0.6742 - 0.7193	0.7538 - 0.8233
Canal B $Im \geq 0$	0.6732 - 0.7058	0.8106 - 0.8605
Canal B $Im < 0$	0.6722 - 0.7162	0.7544 - 0.8230
Escala de gris $Re \geq 0$	0.6709 - 0.7149	0.7557 - 0.8240
Escala de gris $Re < 0$	0.6743 - 0.7189	0.7537 - 0.8231
Escala de gris $Im \geq 0$	0.6732 - 0.7058	0.8106 - 0.8605
Escala de gris $Im < 0$	0.6722 - 0.7162	0.7544 - 0.8230

**Tabla 4. Intervalos para el melanoma  
(media  $\pm 2EE$ )**

Condiciones	Intervalos para melanoma	Intervalos para lesiones benignas
Canal R $Re \geq 0$	0.7079 - 0.7340	0.7556 - 0.8239
Canal R $Re < 0$	0.7125 - 0.7398	0.7538 - 0.8233
Canal R $Im \geq 0$	0.7792 - 0.7945	0.8106 - 0.8605
Canal R $Im < 0$	0.7087 - 0.7349	0.7544 - 0.8230
Canal G $Re \geq 0$	0.7085 - 0.7347	0.7553 - 0.8237
Canal G $Re < 0$	0.7118 - 0.7391	0.7541 - 0.8234
Canal G $Im \geq 0$	0.7792 - 0.7945	0.8106 - 0.8605
Canal G $Im < 0$	0.7087 - 0.7349	0.7544 - 0.8230
Canal B $Re \geq 0$	0.7082 - 0.7346	0.7556 - 0.8239
Canal B $Re < 0$	0.7121 - 0.7393	0.7538 - 0.8233
Canal B $Im \geq 0$	0.7792 - 0.7945	0.8106 - 0.8605
Canal B $Im < 0$	0.7087 - 0.7349	0.7544 - 0.8230
Escala de gris $Re \geq 0$	0.7083 - 0.7345	0.7557 - 0.8240
Escala de gris $Re < 0$	0.7121 - 0.7393	0.7537 - 0.8231
Escala de gris $Im \geq 0$	0.7792 - 0.7945	0.8106 - 0.8605
Escala de gris $Im < 0$	0.7087 - 0.7349	0.7544 - 0.8230

En la tabla 5 se presenta la comparación del nivel de confianza estadístico con otros trabajos relacionados con la identificación de lesiones cancerígenas. Podemos observar que la metodología desarrollada en este trabajo tiene un nivel de confianza mayor comparado con los demás.

**Tabla 5. Comparación con otros trabajos**

Autores	Año de publicación	Nivel de confianza
Betta <i>et al.</i>	2006	Buena precisión
Celebi <i>et al.</i>	2007	92.34%
Rahmana and P. Bhattacharya	2009	72.45%
Cavalcanti and J. Scharcanski	2011	94.54%
Gola <i>et al.</i>	2011	86%
Sadegui <i>et al.</i>	2011	94.3%
Jaleel <i>et al.</i>	2012	Buena precision
Barata <i>et al.</i>	2012	82.1%
Premaladha and Ravichandran	2014	92%
Este trabajo	2015	<b>95.4%</b>

En el apéndice A se muestran las densidades espectrales de las sub-imágenes de una imagen al aplicar un filtro y también se muestran las sub-imágenes binarizadas después de aplicar este paso.

Con el objetivo de llevar a la práctica el desarrollo de este trabajo con esta metodología, se diseñó un sistema de interfaz gráfico de usuario. En el Apéndice B se presenta una descripción de este sistema.

## Capítulo 5

---

### Conclusiones

En este trabajo se presenta una nueva metodología de apoyo para el diagnóstico de cáncer de piel en imágenes con manchas dermatológicas, mediante un análisis espectral usando los filtros clásico, inverso y no lineal ley-k. También se incluye un análisis de frecuencias en los canales R, G, B y escala de grises.

Los resultados obtenidos aplicando cualquier filtro mostraron una diferencia no significativa, esto se debe a las condiciones aplicadas al momento de binarizar la densidad espectral que se obtiene después de aplicar algún filtro, por lo tanto en base a los resultados cualquier filtro puede aplicarse en las imágenes en cualquier canal, de acuerdo a lo anterior en el capítulo 3 sólo se presentan los resultados aplicando el filtro no lineal ley-k.

Los perfiles de intensidad de las imágenes en cada uno de los canales mostraron una diferencia de valores relativamente insignificante, por lo tanto se concluye que la metodología puede ser aplicada usando cualquier canal de intensidad, incluyendo la escala de grises.

Se analizaron imágenes con lesiones cancerígenas y no cancerígenas. Los resultados mostraron que las imágenes de cáncer de piel presentan una franja bien definida de índices espectrales, de esta manera si se analiza una imagen y su índice espectral está dentro de este intervalo, la lesión será diagnosticada como cáncer de piel. La metodología descrita permite adquirir y procesar imágenes de lesiones cutáneas sospechosas de cualquier tamaño, además puede ser una herramienta de apoyo en la prevención de cáncer de piel.



El uso de esta técnica proporciona una mejora significativa en el análisis e interpretación de imágenes por parte de los especialistas, otra ventaja es que puede ser útil para los médicos que no tengan la suficiente experiencia en el área de dermatología. Este trabajo presenta un nivel de confianza del 95.4%.

Además del modelo de color RGB también se utilizaron otros modelos (HSI, CMYK, HSB y YCbCr) sin embargo, los resultados obtenidos no presentaron alguna variación en los intervalos de índices espectrales.

Mediante Matlab se implementó un algoritmo para aplicar la metodología, también se desarrolló una interfaz gráfica de usuario que permite leer una imagen y obtener el resultado de su análisis en tan solo uno o dos segundos. Con esta metodología se puede desarrollar un sistema que proporcione un diagnóstico rápido, el análisis de manchas mediante imágenes es simple y rápido, además es una herramienta no invasiva para el paciente.

Trabajos futuros pueden aplicar esta técnica de índices espectrales para la detección de algunas otras enfermedades de la piel manifestadas en manchas.

## Referencias

---

- Abdul, Ahad, S. A., Mohammad A. K. and Seyda, R. J., (1990). Improved correlation discrimination using an amplitude modulated phase-only filter. *Appl. Opt.* 29(2), 233-236.
- American Cancer Society, (2015). *Facts and Figures 2015*.
- Barata, C., Marques, J.S. and Rozeira, J., (2012). A system for the detection of pigment network in dermoscopy images using directional filters. *IEEE Trans. Biomed. Eng.* 59(10), 2744–2754.
- Berg, A.O., and Best, D., (2001). U.S. Preventive Services Task Force., Screening for Skin Cancer. *Am. J. Prev. Med.* 20(3), 44–46.
- Betta, G., Di Leo, G., Fabbrocini, G., Paolillo, A. and Sommella, P., (2006). Dermoscopic image-analysis system: Estimation of atypical pigment network and atypical vascular pattern. Presented at the International Workshop on Medical Measurement and Applications. 63–67.
- Bracewell, R. N., (1978). *The Fourier transform and its applications*. (2nd ed.), New York, Chap.12McGraw-Hill.
- Bueno-Ibarra, M.A, Chavez-Sanchez, M.A y Álvarez-Borrego, J., (2010). Nonlinear Law Spectral Technique to Analyze White Spot Syndrome Virus Infection., *IJALS.* 2(3,4), 125-132.
- Cavalcanti, P.G. and Scharcanski, J., (2011). Automated prescreening of pigmented skin lesions using standard cameras. *Comput. Med. Imaging Graph.* 35, 481–91.
- Celebi, M.E., Kingravi, H. A, Uddin, B., Iyatomi, H., Aslandogan, Y.A., Stoecker, W. V and Moss, R.H., (2007). A methodological approach to the classification of dermoscopy images. *Comput. Med. Imaging Graph.* 31, 362–73.
- Eide, M.J., Asgari, M.M., Fletcher, S.W., Geller, A.C., Halpern, A.C., Shaikh, W.R., Li, L., Alexander, G.L., Altschuler, A., Dusza, S.W., Marghoob, A. A, Quigley, E. A and Weinstock, M. A, (2013). Effects on skills and practice from a web-based skin cancer course for primary care providers. *J. Am. Board Fam. Med.* 26(6), 648–57.

- Orozco-Guillén, Enrique, E., Iruretagoyena-Garcia, G., Vazquez y Montiel. S., Delgado-Atencio, J. A., CAstro-Ramos, J., y Delgado, Gutierrez, F., (2010). Métodos de clasificación para identificar lesiones en piel a partir de espectros de reflexión difusa., *Rev. Ing. Biomédica* 4, 34–40.
- Gola-Isasi, A., Zapirain-García, B., y Mendez-Zorrilla, A., (2011). Melanomas non-invasive diagnosis application based on the ABCD rule and pattern recognition image processing algorithms. *Comput. Biol. Med.* 41, 742–55.
- Gonzalez, R. C., and Woods, R. E. (2002). *Digital Image Processing* (2nd ed.), New Jersey, Prentice Hall.
- Gonzalez, R. C., and Woods, R. E. (1992). *Digital Image Processing*. Addison-Wesley.
- Goodman J. W. (2005). *Introduction to Fourier Optics*. (3rd ed.), Greenwood Village, CO. Roberts and Company Publishers.
- Gutiérrez-Vidrio R.M., (2003). Cáncer de piel. *Rev Fac Med UNAM* 46(4), 166–171.
- Jaleel, J.A., Salim, S. and Aswin, R.B., (2012). Artificial Neural Network Based Detection of Skin Cancer., 1, 200–205.
- Korotkov, K., and Garcia, R., (2012). Computerized analysis of pigmented skin lesions: a review., *Artif. Intell. Med.* 56, 69–90.
- Kricker, A., Armstrong, B., Hansen, V., Watson, A., Singh-Khaira, G., Lecathelinais, C., Goumas, C. and Girgis, A., (2014). Basal cell carcinoma and squamous cell carcinoma growth rates and determinants of size in community patients. *J. Am. Acad. Dermatol.* 70, 456–64.
- Kumar, B. V. K., and Hassebrook, L., (1990). Performance measures for correlation filters. *Appl. Opt.* 29(20), 2997-3006.
- Lacy, K. and Alwan, W., (2013). Skin cancer. *Medicine (Baltimore)*. 41, 402–405.
- Ogden, S. and Telfer, N.R., (2009). Skin cancer. *Medicine (Baltimore)*. 37(6), 305–308.
- Papoulis, A. (1962). *The Fourier Integral and Its Applications*. McGraw Hill.
- Premaladha, J. and Ravichandran, K.S., (2014). Asymmetry Analysis os Malignant Melanoma Using Image Processing: A survey, *Science Alert.* 7(2), 45-53.

- Rahman, M.M. and Bhattacharya, P., (2010). An integrated and interactive decision support system for automated melanoma recognition of dermoscopic images. *Comput. Med. Imaging Graph.* 34(6), 479–86.
- Sadeghi, M., Razmara, M., Lee, T.K. and Atkins, M.S., (2011). A novel method for detection of pigment network in dermoscopic images using graphs. *Comput. Med. Imaging Graph.* 35(2), 137–143.
- Saraiya, M., Hall, H.I., Thompson, T., Hartman, A., Glanz, K., Rimer, B., Rose, D., (2004). Skin cancer screening among U.S. adults from 1992, 1998, and 2000 National Health Interview Surveys. *Prev. Med. (Baltimore)*. 39, 308–14.
- Smaoui, N. and Bessassi, S., (2013). A developed system for melanoma diagnosis. *Int. J. Comp. Vis.* 3(1), 10–17.
- Telfer, N.R., Colver, G.B. and Morton, C. A, (2008). Guidelines for the management of basal cell carcinoma. *Br. J. Dermatol.* 159(1), 35–48.
- Uchida, (2013). Image processing and recognition for biological images. *Dev. Growth Differ.* 55(4).
- Vander Lugt, A. B., (1964). Signal detection by complex spatial filtering. *IEEE Trans. Inf. Theory*, 10, 139-145.


## Apéndice A

A continuación se presenta el análisis espectral de la imagen de la figura A.1.



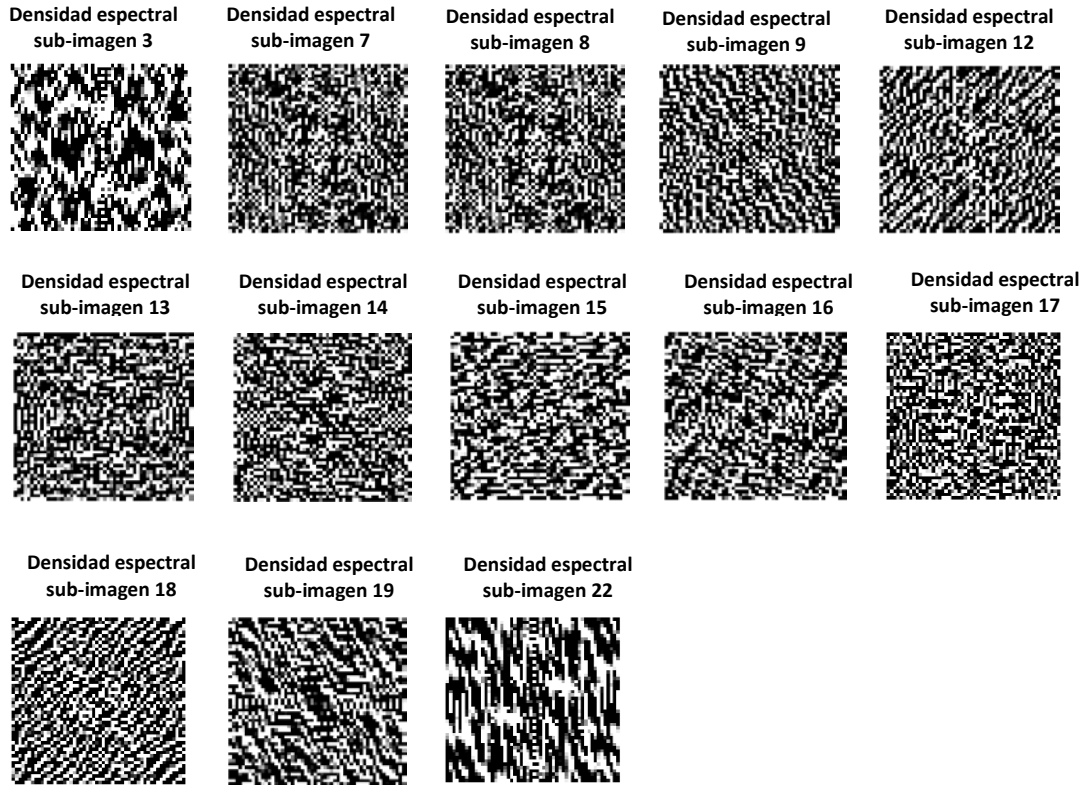
**Figura A.1.** Imagen a color.

Posteriormente la imagen en canal verde  $I_w^{\lambda_G}(x, y)$  es multiplicada por su máscara binaria y se divide en 25 sub-imágenes (esta división se puede observar en figura A.2 (a)), como se mencionó anteriormente el siguiente paso consiste en seleccionar sólo aquellas sub-imágenes que tengan información mayor o igual a un tercio del total de su área respectiva, para este caso la figura A.2 (b), muestra el resultado de esta condición, es decir sólo las sub-imágenes que serán analizadas.



**Figura A.2.** Obtención de sub-imágenes para su análisis: (a) matriz de sub-imágenes  $I_w^{\lambda_G}(x, y)$  y (b) sub-imágenes.

Después a cada sub-imagen se le aplica un filtro, para obtener las densidades espectrales que contienen las frecuencias, en este ejemplo se aplicó el filtro ley-k para la imagen en canal verde, la figura A.3 muestra las densidades espectrales obtenidas, cabe mencionar que estas sub-imágenes están en el dominio de las frecuencias y contienen información compleja.



**Figura A.3.** Densidades espectrales de las sub-imágenes obtenidas mediante el filtro no lineal ley-k.

Posteriormente cada una de estas sub-imágenes es binarizada, para este caso se tomó la siguiente condición:

$$SSF_1(F_{w_j}^{\lambda_c}(u, v)) = \begin{cases} 1, & \text{Si } Re(F_{w_j}^{\lambda_c}(u, v)) \geq 0 \\ 0, & \text{cualquier otro valor} \end{cases},$$

donde se toma la parte real de la densidad espectral.

La figura A.4 muestra las densidades espectrales binarizadas de las sub-imágenes anteriores.

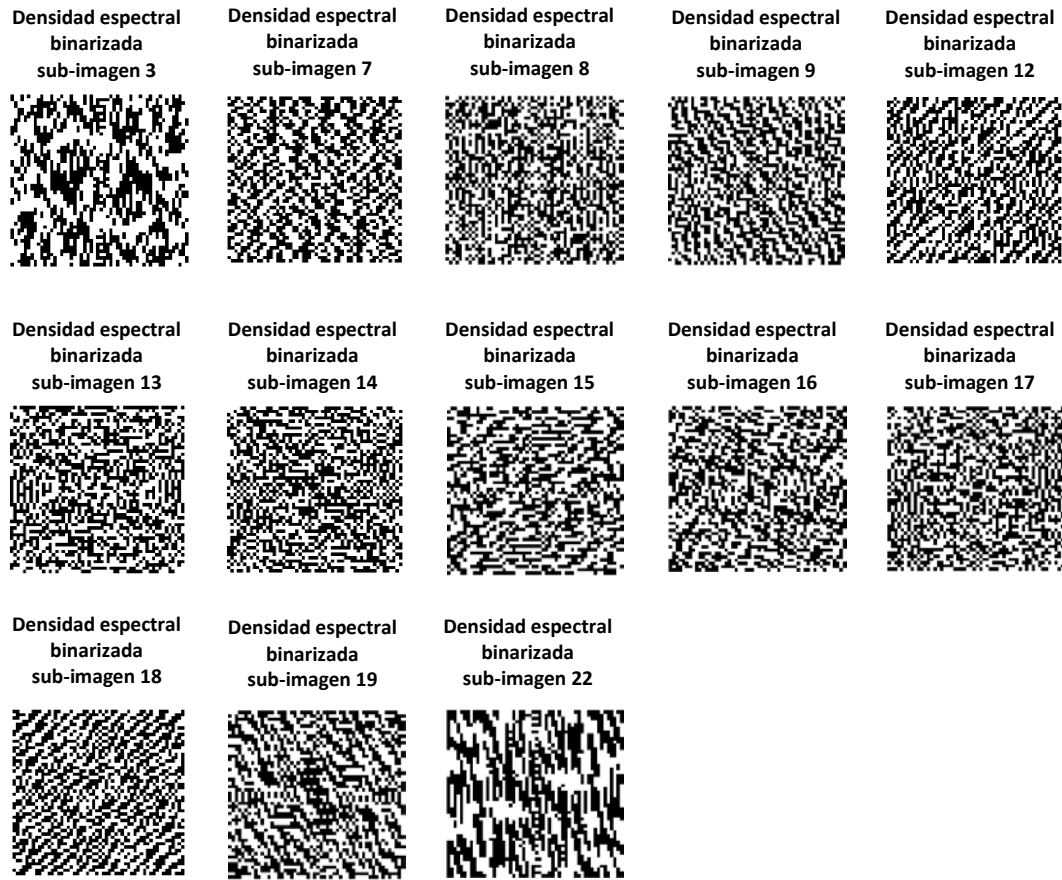


Figura A.4. Densidades espectrales binarizadas.

La densidad espectral de la sub-imagen 3 (de la figura A.4) representada por la función  $F_{w3}^{\lambda_G}(u,v)$  se muestra en la figura A.5 (a) y la binarización de esta se muestra en la imagen A.5 (b). En estas imágenes se puede visualizar con claridad el cambio de una densidad a otra.



**Figura A.5.** Densidades: (a) densidad espectral obtenida al aplicar el filtro no lineal ley-k y (b) densidad espectral binarizada.



## *Apéndice B*

### **Descripción del sistema de interfaz gráfico de usuario**

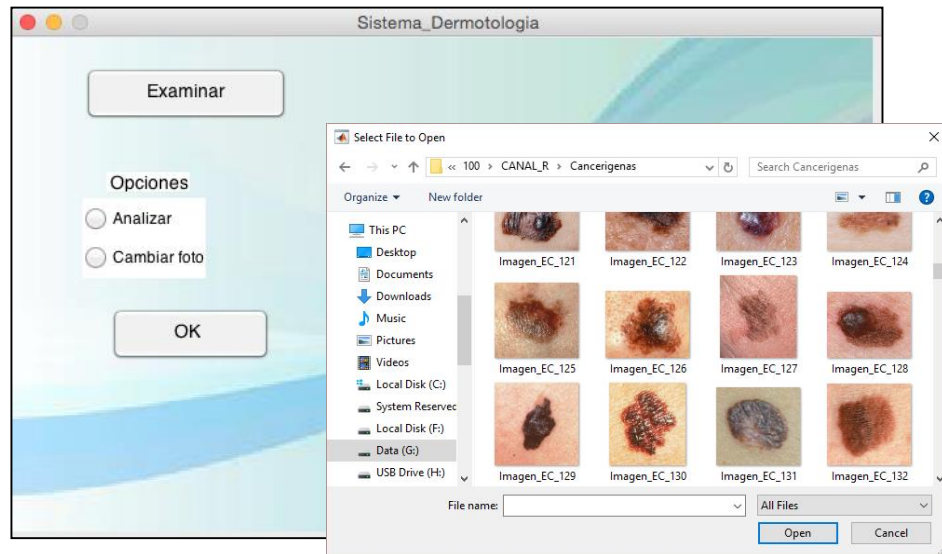
El cáncer de piel es una de las enfermedades más frecuentes a nivel mundial, tomando esto en consideración se planteó la necesidad de un sistema de valoración médica de imágenes de manchas de piel, capaz de procesar la información de la imagen. Fue así que se desarrolló la metodología del presente trabajo como herramienta de apoyo para la valoración de manchas de piel.

Este sistema ha sido desarrollado bajo el entorno de Matlab para el funcionamiento en plataformas Windows y Mac, en un ambiente amigable para cualquier usuario. Por otra parte, su ejecución y tiempo de respuesta es relativamente corto siendo un sistema automatizado.

A continuación se muestra una breve explicación para el usuario de este sistema. En la figura B.1 se muestra la ventana principal, la cual tiene el botón de examinar una imagen que puede ser leída de cualquier archivo almacenado en la computadora como se muestra en la figura B.2.

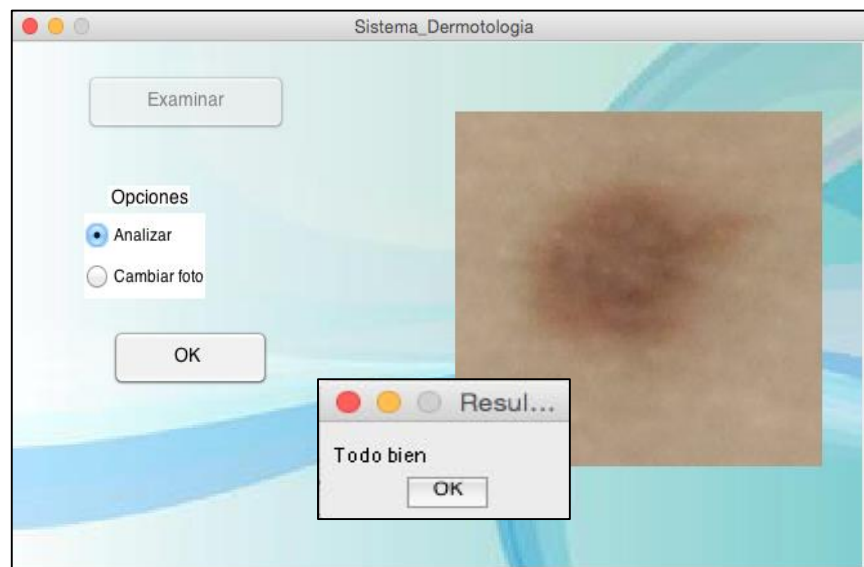


**Figura B.1.** Pantalla principal.



**Figura B.2.** Lectura de imagen.

Una vez que se lee la imagen deseada se tienen dos opciones, la primera se utiliza para analizar la imagen y obtener el resultado, en la figura B.3 se muestra la lectura de una imagen con una lesión benigna, el sistema analiza la imagen y da como resultado un mensaje que indica no ser una lesión cancerígena.



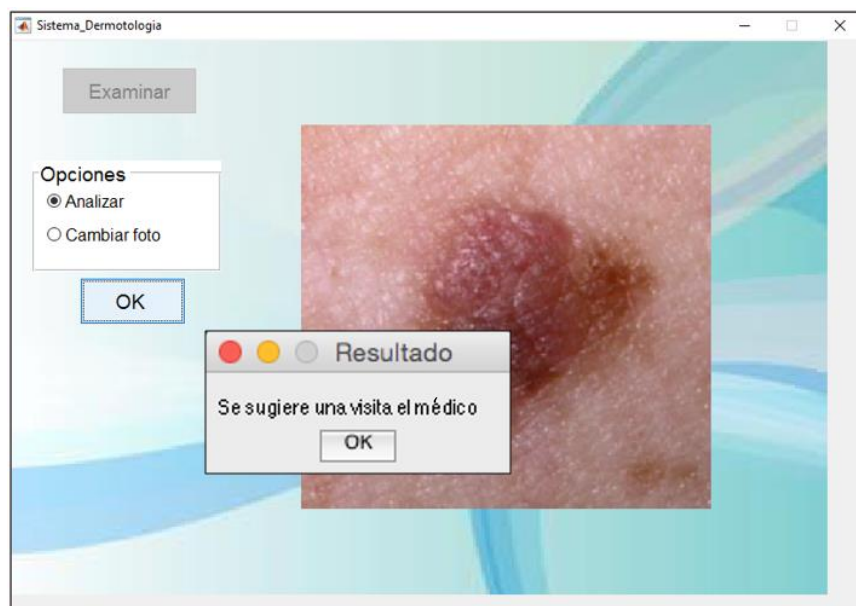
**Figura B.3.** Análisis de la imagen.

La segunda opción permite cambiar de imagen, de igual manera esta se puede encontrar en cualquier archivo o carpeta de la computadora, en la figura B.4 se puede visualizar esta opción seleccionada.



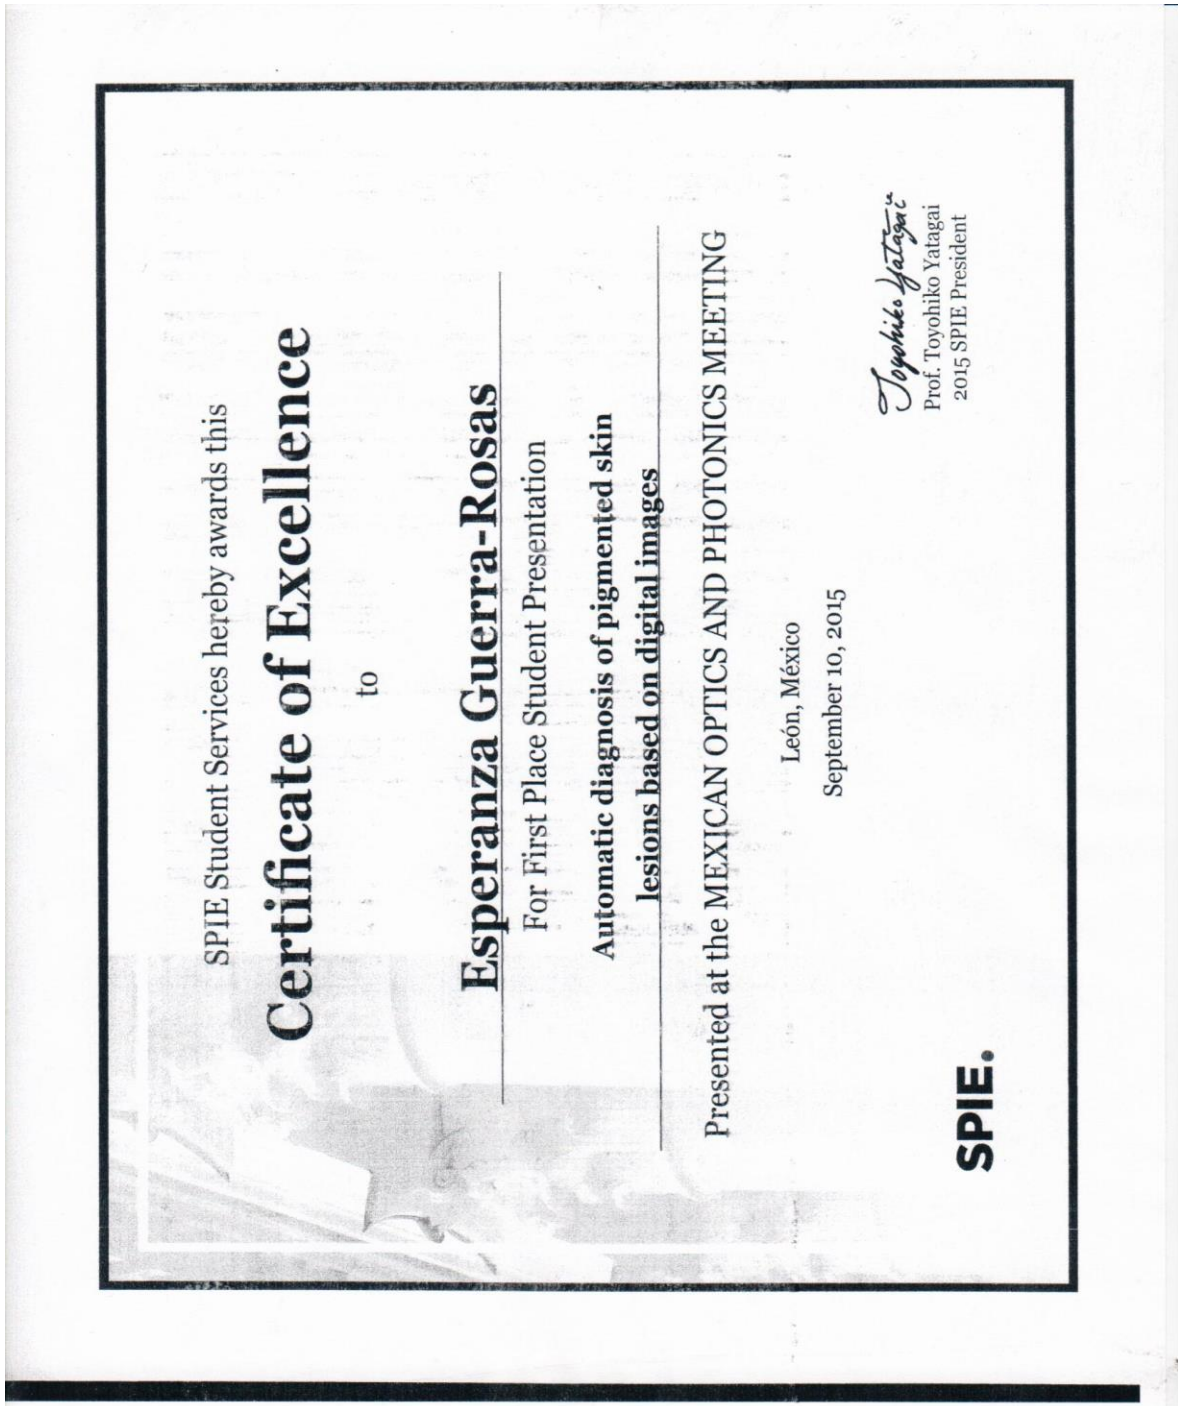
**Figura B.4.** Cambio de imagen.

Una vez que se lee la imagen se analiza internamente por el sistema, por lo tanto en figura B.5 se muestra el análisis de una imagen cancerígena, para este caso se despliega el mensaje de texto el cual sugiere hacer una visita médica.



**Figura B.5.** Análisis de una nueva imagen.

En la participación en el congreso internacional Mexican Optics and Photonics Meeting, se presentó parte de la metodología desarrollada, donde se obtuvo el único premio otorgado al área de Óptica por parte del SPIE.



El desarrollo de este trabajo aportará una contribución en el área médica. Cabe mencionar que esta metodología está en proceso de patente.

  
Gobierno del Estado  
Libre y Soberano  
de Baja California

“60 millones de pesos invertidos en Medicamentos para las personas con VIH/SIDA en B.C.”

ENTIDAD: INSTITUTO DE SERVICIOS DE SALUD PÚBLICA DEL ESTADO DE B. C.  
SECCIÓN: JURISDICCIÓN DE SERVICIOS DE SALUD NO. IV.  
ÁREA: DPTO. DE EXTENSIÓN DE COBERTURA  
NUMERO DE OFICIO: Ext. Cob/116-14.

**Asunto:** El que se Indica.

Vicente Guerrero, Ensenada a 22 de Octubre de 2015.

**A QUIEN CORRESPONDA  
P R E S E N T E:**

Por este conducto le envié un cordial saludo y le manifiesto mi aprobación para que a partir de Enero del 2016 sea utilizado el nuevo método de detección de cáncer en la piel, desarrollado por la estudiante de Doctorado Esperanza Guerra Rosas, bajo la dirección del Dr. Josué Álvarez Borrego, Investigador del Departamento de óptica del CICESE, En el entendido que se refiere a una intervención no invasiva que requiere la observación de una fotografía de la piel.

Así mismo solicito se nos informe sobre los preparativos previos para recibir la tecnología descrita

Sin más por el momento, agradezco la atención prestada, quedo a sus órdenes.

**ATENTAMENTE**

  
Dr. GUILLERMO GALICIA SANCHEZ.  
Coord. Del Dpto. de Ext. De Cobertura.  
IV. JURISDICCIÓN DE SERVICIOS DE SALUD

  
UNIDADES MEDICAS MOVILES PROSPERA  
DEPARTAMENTO DE EXT. DE COBERTURA  
IV JURISDICCION VICENTE GUERRERO B.C.

CCP. Archivo.

  
CALLE FRANCISCO DE BORJA 35, COLONIA TRECE DE MAYO,  
VICENTE GUERRERO, ENSENADA, B.C., C.P. 22920  
TÉLS. CONMUTADOR (616)1663956 Y 1664691 Ext. 6102

  
SALUD BAJA CALIFORNIA  
UNIDADES MEDICAS MOVILES PROSPERA

## Artículos derivados de la tesis

---

### **Artículo en revista con arbitraje:**

Guerra-Rosas Esperanza, Álvarez-Borrego Josué, “*Methodology for diagnosing of skin cancer on images of dermatologic spots by spectral analysis*”, Biomedical Optics Express, 6(10), 242232, (September 09, 2015); DOI:10.1364/BOE.6.003876

### **Artículo en memoria de congreso internacional con arbitraje:**

Guerra-Rosas Esperanza, Álvarez-Borrego Josué, Coronel-Beltrán Ángel, “*Diagnosis of skin cancer using image processing*”, Athens, Greece, AIP Conf. Proc. 1618, 147 (2014), 4-7 April, doi: 10.1063/1.4897704, <http://dx.doi.org/10.1063/1.4897704>

# Methodology for diagnosing of skin cancer on images of dermatologic spots by spectral analysis

Esperanza Guerra-Rosas<sup>1,2</sup> and Josué Álvarez-Borrego<sup>3,4</sup>

<sup>1</sup>Departamento de Investigación en Física, Universidad de Sonora (UNISON), Luis Encinas y Rosales S/N, Col. Centro, Hermosillo, Sonora, C.P. 83000, Mexico

<sup>2</sup>esperanza\_guerra@yahoo.com.mx

<sup>3</sup>Centro de Investigación Científica y de Educación Superior de Ensenada (CICESE), División de Física Aplicada, Departamento de Óptica, Carretera Ensenada-Tijuana No. 3918, Fraccionamiento Zona Playitas, Ensenada, Baja California, C.P. 22860, Mexico

<sup>4</sup>josue@cicese.mx

**Abstract:** In this paper a new methodology for the diagnosing of skin cancer on images of dermatologic spots using image processing is presented. Currently skin cancer is one of the most frequent diseases in humans. This methodology is based on Fourier spectral analysis by using filters such as the classic, inverse and k-law nonlinear. The sample images were obtained by a medical specialist and a new spectral technique is developed to obtain a quantitative measurement of the complex pattern found in cancerous skin spots. Finally a spectral index is calculated to obtain a range of spectral indices defined for skin cancer. Our results show a confidence level of 95.4%.

©2015 Optical Society of America

**OCIS codes:** (100.2000) Digital image processing, (070.2615) Frequency filtering.

## References and links

1. M. J. Eide, M. M. Asgari, S. W. Fletcher, A. C. Geller, A. C. Halpern, W. R. Shaikh, L. Li, G. L. Alexander, A. Altschuler, S. W. Dusza, A. A. Marghoob, E. A. Quigley, and M. A. Weinstock; Informed (Internet course for Melanoma Early Detection) Group, "Effects on skills and practice from a web-based skin cancer course for primary care providers," *J. Am. Board Fam. Med.* **26**(6), 648–657 (2013).
2. American Cancer Society. Cancer Facts and Figs. (2014).
3. N. R. Telfer, G. B. Colver, and C. A. Morton; British Association of Dermatologists, "Guidelines for the management of basal cell carcinoma," *Br. J. Dermatol.* **159**(1), 35–48 (2008).
4. A. Kricke, B. Armstrong, V. Hansen, A. Watson, G. Singh-Khaira, C. Lecathelinais, C. Goumas, and A. Girgis, "Basal cell carcinoma and squamous cell carcinoma growth rates and determinants of size in community patients," *J. Am. Acad. Dermatol.* **70**(3), 456–464 (2014).
5. E. A. Gordon Spratt and J. A. Carucci, "Skin cancer in immunosuppressed patients," *Facial Plast. Surg.* **29**(5), 402–410 (2013).
6. S. Ogden and N. R. Telfer, "Skin cancer," *Medicine (Baltimore)* **37**(6), 305–308 (2009).
7. K. Korotkov and R. Garcia, "Computerized analysis of pigmented skin lesions: a review," *Artif. Intell. Med.* **56**(2), 69–90 (2012).
8. A. O. Berg, D. Best; US Preventive Services Task Force, "Screening for Skin Cancer: recommendations and rationale," *Am. J. Prev. Med.* **20**(3 Suppl), 44–46 (2001).
9. M. M. Rahman and P. Bhattacharya, "An integrated and interactive decision support system for automated melanoma recognition of dermoscopic images," *Comput. Med. Imaging Graph.* **34**(6), 479–486 (2010).
10. A. G. Isasi, B. G. Zapirain, and A. M. Zorrilla, "Melanomas non-invasive diagnosis application based on the ABCD rule and pattern recognition image processing algorithms," *Comput. Biol. Med.* **41**(9), 742–755 (2011).
11. P. G. Cavalcanti and J. Scharcanski, "Automated prescreening of pigmented skin lesions using standard cameras," *Comput. Med. Imaging Graph.* **35**(6), 481–491 (2011).
12. J. A. Jaleel, S. Salim, and R. B. Aswin, "Artificial neural network based detection of skin cancer," *IJAREEIE* **1**, 200–205 (2012).
13. M. Sadeghi, M. Razmara, T. K. Lee, and M. S. Atkins, "A novel method for detection of pigment network in dermoscopic images using graphs," *Comput. Med. Imaging Graph.* **35**(2), 137–143 (2011).
14. C. Barata, J. S. Marques, and J. Rozeira, "A system for the detection of pigment network in dermoscopy images using directional filters," *IEEE Trans. Biomed. Eng.* **59**(10), 2744–2754 (2012).

15. G. Betta, G. Di Leo, G. Fabbrocini, A. Paolillo, and P. Sommella, "Dermoscopic image-analysis system: Estimation of atypical pigment network and atypical vascular pattern," presented at the International Workshop on Medical Measurement and Applications, Benevento, Italy, 20–21 April 2006.
  16. M. E. Celebi, H. A. Kingravi, B. Uddin, H. Iyatomi, Y. A. Aslandogan, W. V. Stoecker, and R. H. Moss, "A methodological approach to the classification of dermoscopy images," *Comput. Med. Imaging Graph.* **31**(6), 362–373 (2007).
  17. N. Smaoui and S. Bessassi, "A developed system for melanoma diagnosis," *Int. J. Comput. Vis.* **3**(1), 10–17 (2013).
  18. J. Premaladha and K. S. Ravichandran, "Asymmetry analysis of malignant melanoma using image processing: a survey," *Science Alert* **7**(2), 45–53 (2014).
  19. E. Guerra-Rosas, J. Álvarez-Borrego, and Á. Coronel-Beltrán, "Diagnosis of skin cancer using image processing," *Proceedings of AIP Conference* 1618, 155 (2014).
  20. S. Uchida, "Image processing and recognition for biological images," *Dev. Growth Differ.* **55**(4), 523–549 (2013).
  21. A. B. Vander Lugt, "Signal detection by complex spatial filtering," *IEEE Trans. Inf. Theory* **10**(2), 139–145 (1964).
  22. A. A. S. Awwal, M. A. Karim, and S. R. Jahan, "Improved correlation discrimination using an amplitude-modulated phase-only filter," *Appl. Opt.* **29**(2), 233–236 (1990).
  23. B. V. K. V. Kumar and L. Hassebrook, "Performance measures for correlation filters," *Appl. Opt.* **29**(20), 2997–3006 (1990).
  24. R. E. Guerrero and J. Álvarez Borrego, "Nonlinear composite filter performance," *Opt. Eng.* **48**(6), 067021 (2009).
  25. M. A. Bueno-Ibarra, M. C. Chávez-Sánchez, and J. Álvarez-Borrego, "Nonlinear law spectral technique to analyze white spot syndrome virus infection," *IJALS* **2**(3,4), 125–132 (2010).
- 

## 1. Introduction

Skin cancer is one of the diseases that affect humans. It is caused by the development of cancerous cells on any of the layers of skin and occurs when cells in a body part begin to grow out of control and spread to other organs and tissues. United States is one of the countries that has had greater incidence of this disease and represents an important health problem. There are three major types of skin cancer which are basal cell carcinoma, squamous cell carcinoma and melanoma [1, 2]. Basal cell carcinoma is the most common skin cancer, however is the least dangerous if it is detected early. This cancer appears in cells that are in the deeper layers of skin, usually in parts of the body that are exposed to the sun such as the face, head, neck, ears, shoulders and back, however occurs most often in the face, this type rarely causes a metastasis [3–6]. Squamous cell carcinoma is the second most common type of skin cancer, which appears in the cells that make up the upper skin layers, it is more likely to spread to areas under the skin. It is usually found on parts of the body that are exposed to uv light, therefore it can appear on legs or feet, it can be locally invasive, it may be able to reach large sizes if is not detected early. It is able to cause metastasis [6], classically it is presented as a nodule, papule or tumor [5]. Melanoma is the least common compared to other types, but is the most dangerous because it can cause death if is not detected early. It is able to take place anywhere on the skin, but is more likely to develop in certain locations. Like basal cell and squamous cell cancers, melanoma is almost always curable in its early stages [6, 7].

Skin cancer is very common in Europe, Australia and USA [6] and is almost always curable if recognized and treated early. The major risk factors related are skin color, sun exposure, climate, advanced age, genetic and familial history. The best way to detect melanoma is to recognize a new spot in the skin or a spot that is changing in size, shape and color. Early detection of skin cancer can avoid death [8].

Currently this disease represents a serious health problem, the search for an accurate clinical diagnosis has been a constant concern for dermatologists. Nowadays some methodologies on the area of image processing have been developed using algorithms or systems for detection and classification by means of techniques and computational methods, which have been applied in solving medical problems. These methodologies can be a very effective tool especially where there are not specialists, on other hand it is also a noninvasive tool for the patient [7–9]. Over the last decades image processing has been applied in different



areas, allowing to improve the information on an image for its interpretation, representation, description, and processing.

In the last years several studies and works related with images of pigmented skin lesions for diagnosis and classifying skin lesion such as skin cancer have been developed by means of digital images analysis. Their main objective have been to provide an accurate diagnosis. Most studies are related to the diagnosis of malignant melanoma. Gola *et al.* [10] developed an automated dermatological tool to identify melanoma. Their algorithms are based on identifying three categories: reticular, globular and homogeneous blue pigmentation. An important aspect of their work is to extract the shape of the skin lesion and then extract features of interest. Each algorithm cannot make a final decision therefore they will develop a system correlating all algorithms in order to perform a correct diagnosis. Rahman and Bhattacharya [9] proposed a similar method to recognize melanoma malignant. They presented a decision system using different classifiers such as support vector machine (SVMs), k-nearest neighbors (K-NNs) and Gaussian maximum likelihood (G-ML). The morphology of the lesion is detected applying a thresholding-based segmentation method then the lesion mask is obtained which contains the area of the lesion in the grey level. Color features are extracted from the lesion mask to train the respective classifiers after a comparison of single classifiers are performed, where the highest percentage of precision obtained with one of the classifiers was 72.45%. In their method melanoma, benign lesions and dysplastic nevi were classified. Cavalcanti and Scharcanski [11] proposed a method for classifying pigmented skin lesions as benign or malignant using two classifiers: the k-nearest neighbors (KNN) and the KNN followed by a Decision tree (KNN-DT). First a preprocessing is applied to the image where shading effects are attenuated, for this the original image of the RGB color space is converted to HSV color space. Then a segmentation method is developed considering texture and color patterns of the image, in this step some operation are applied to eliminate imperfections caused by noise. Of the segmented image a set of features is extracted according to the ABCD rule (i.e., asymmetry, border irregularity color variation and diameter). Both classifiers were trained with these features. The result showed an accuracy of 94.54% to predict a lesion as benign or malignant. The methodology proposed by Jaleel *et al.* [12] is based on image processing techniques using Artificial Neuronal Network. Their main objective was classify melanoma from other skin diseases. The image was preprocessed in order to remove the noise present in it. Then it is smoothed by the median filter. After the image is segmented and binarized using threshold segmentation. 2D wavelet transform is applied over the segmented image to extract the features such as mean, standard deviation, absolute mean, L1 norm and L2 norm. The network was trained with features. Therefore its accuracy rate is good however it can be improved for this system. Given a dermoscopic image Sadegui *et al.* [13] classified the absence or presence of a pigmented network. First the image was preprocessed applying a high-pass filter to remove the low-frequency noise. This step was made on different color transformations (NTSC,  $L^*a^*b^*$ , red, green and blue). A Laplacian of Gaussian filter (LoG) was applied in order to find meshes or cyclic structures, which represent the presence of a pigmented network region. The set of subgraphs obtained is converted to a graph using an eight connected components analysis, after noise or unwanted structures are removed. Considering distance between nodes corresponding to a hole found in each subgraph a high-level graph is created. By mean of this graph is obtained the density ratio, which compares the number of edges in the graph with its vertices and the entire lesion area. Density is used to detect a pigmented network. They reported a percentage of classification of 94.3%. Barata *et al.* [14] proposed a system for detecting a pigmented network. This method uses directional filters. The image is converted in grayscale to remove hair and reflections caused by the dermoscopy gel. The intensity property is taken to enhance the pigment network applying directional filters and geometry or spatial organization is used to generate a binary net-mask. Therefore spatial organization is carried out whit the connection of all pixels. Then a label is assigned to each binary image

that is with or without pigmented network. Features are extracted and used to train a classifier using the boosting algorithm. The algorithm was tested on a data set of 200 dermoscopy image (88 with pigment network and 112 without). They reported results of 82.1% for the classification. Betta *et al.* [15] described a method for detecting a typical pigmented network. This methodology is based on the combination of structural and spectral technique. The structural technique is made to identify the texture defined by local discontinuities such as lines and/or points. This is obtained by comparing the monochromatic image with the image which applied median filter. The spectral technique is based on the Fourier analysis of the image to obtain the spatial period of texture in this way a “regions with network” mask is created. Therefore this mask joins with segmented mask obtaining a “network image”, where the lesion area and pigment network are highlight. Finally to quantify the nature of the network two indices related to the spatial and chromatic variability have been obtained. To evaluate the performance of this method 30 images were evaluated.

The majority of the studies published in the literature such as [16–18] include similar stages as in the works mentioned above. These methods consists, generally of four stages which are: (i) acquire de image set, (ii) segmentation (which include several methods i.e techniques based on edges, thresholding, histogram segmentation, region growing, etc.), (iii) feature extraction (iv) classification or detection of a lesion for diagnosis.

It is important to evaluate patients with spotted skin quickly and efficiently through a noninvasive technique easy to implement. The importance of obtaining an accurate diagnostic method has led to develop techniques based on image processing

The aim of this work has been to develop a new methodology for diagnosing skin cancer based on images processing techniques applying different techniques of Fourier spectral filtering such as classic, inverse and k-law nonlinear [19].

Fourier spectral analysis techniques have demonstrated the capability to analyze important features from images in several fields being one of the most powerful tools.

## **2. Materials and methods**

### *2.1 Image acquisition and construction of image bank*

The image bank was created with images of skin cancer provided by the Dermatology Department of Centenario Hospital Hidalgo and the Instituto Nacional de Cancerología (INcan) in Mexico City. The images were classified as basal cell carcinoma, squamous cell carcinoma and melanoma by certified dermatologists after histopathological examination. Some images are shown in Fig. 1.




Fig. 1. Skin cancer images.

## 2.2 Multispectral analysis

Appendix A shows the mathematical analysis for skin cancer images. It can be observed after applying the methodology, the results do not present significant difference, thus any color channel or grayscale can be used.

## 2.3 Skin lesion segmentation

Image segmentation is one of the most important stages in image processing. Its objective is to partition an input image into regions or categories, it is still one of the most difficult tasks, however several segmentation techniques have been developed thus allowing its improvement. Biological images, because its complexity, have been more difficult for obtaining a good segmentation [20]. In this case our objective is to remove the healthy skin from the image to obtain the region that contain the skin lesion.

The thresholding method is used in this paper. First the original image is converted to grayscale, then the threshold method is applied, and finally the output is a binary image which we call a binary mask. Figure 2 shows the segmentation process.




Fig. 2. Segmentation (a) Original image, (b) grayscale image, (c) Binary mask.

The binary mask function,  $I_{mask}(x, y)$ , to obtain the binary image can be expressed as:

$$I_{Mask}(x, y) = \begin{cases} 1 & \text{if } f_w^{\lambda_{Gray}}(x, y) > T \\ 0 & \text{if } f_w^{\lambda_{Gray}}(x, y) \leq T \end{cases} \quad (1)$$

Where  $T$  is a threshold value and  $x, y$  are the coordinates of the threshold value point. Then all the gray level values greater than  $T$  will be classified as white taking the value 1, and all values less than or equal to  $T$  will be black taking the value 0. Finally, in order to do the binary mask the values are interchanged, of this way the interest area is filled with ones.

To avoid problems when determining the threshold value, the Otsu method was used which provides the optimal threshold value under the criterion of maximum variance between the background and the object. This can be expressed by

$$T = \max(\sigma^2). \quad (2)$$

The function  $A_{mask}$  contains the total area of binary mask over the region of interest to analyze, given by:

$$A_{mask} = \sum_{x,y} I_{Mask}(x, y), \text{ for } I_{Mask} > 0. \quad (3)$$

The intensity matrix data of the selected channel are bitwise multiplied by the binary mask function  $I_{Mask}(x, y)$ , obtaining the function  $I_w^{\lambda_c}(x, y)$  which contains the information of interest of the spot that will be analyzed, thus  $I_w^{\lambda_c}(x, y) = f_w^{\lambda_c}(x, y) \Delta I_{Mask}(x, y)$  where the symbol  $\Delta$  represents a multiplication.

#### 2.4 Sub-images

The binary image was divided into twenty five sub-images  $I_{Mask}(x, y)$ , where each sub-image  $A_{Mask_j}$  has its respective area, ( $j = 1, \dots, 25^{th}$ ). The sub-images are show in Fig. 3.




Fig. 3. Sub-images  $I_{mask_j}$  of the binary mask.

Moreover, the image of the function  $I_w^{\lambda_c}(x, y)$  is divided into twenty five sub-images as shown in Fig. 4 each sub-image is represented by the corresponding function  $I_{w_j}^{\lambda_c}(x, y)$ .




Fig. 4. Sub-images  $I_{w_j}^{\lambda_c}(x, y)$ ,  $j = 1, \dots, 25^{th}$ .

The sub-image  $I_{w_j}^{\lambda_c}(x, y)$  is selected under the condition  $A_{Mask_j} \geq \frac{1}{3} [I_{Mask_j}(x, y)]$ , in order to select only sub-images that contain information greater than or equal to one third of the total area of the sub-image. Figure 5 shows the sub-images that meet the condition for this case.




Fig. 5. Sub-image  $I_{w_j}^{\lambda_c}(x, y)$  with information greater than or equal to one third of the area.

## 2.5 Digital filters (spatial filters)

Appendix B gives us a complete description of the three spatial filters used in this work: classic filter [21], inverse filter [22, 23] and the k-law nonlinear filter [24].

## 2.6 Spectral index

The spectral density  $SSF$  may be defined as a function that contains the spectral properties of  $f_{w_j}^{\lambda_c}(u, v)$  function, therefore the spectral index is described as a quantitative measure of complex patterns [25].

The function  $f_{w_j}^{\lambda_c}(u, v)$  is analyzed with the conditions

$$\begin{aligned} SSF_1(f_{w_j}^{\lambda_c}(u, v)) &= \begin{cases} 1, & \text{If } Re(f_{w_j}^{\lambda_c}(u, v)) \geq 0 \\ 0, & \text{otherwise} \end{cases}, \\ SSF_2(f_{w_j}^{\lambda_c}(u, v)) &= \begin{cases} 1, & \text{If } Re(f_{w_j}^{\lambda_c}(u, v)) < 0 \\ 0, & \text{otherwise} \end{cases}, \\ SSF_3(f_{w_j}^{\lambda_c}(u, v)) &= \begin{cases} 1, & \text{If } Im(f_{w_j}^{\lambda_c}(u, v)) \geq 0 \\ 0, & \text{otherwise} \end{cases}, \\ SSF_4(f_{w_j}^{\lambda_c}(u, v)) &= \begin{cases} 1, & \text{If } Im(f_{w_j}^{\lambda_c}(u, v)) < 0 \\ 0, & \text{otherwise} \end{cases}, \end{aligned} \quad (4)$$

where  $Re(f_{w_j}^{\lambda_c}(u, v)), Im(f_{w_j}^{\lambda_c}(u, v))$  are the real and imaginary parts respectively. These conditions are applied to determine which provides better results.

The spectral index for each sub-image is obtained by the ratio of the sum of the unit values present in Eq. (4), and the sum of the unit values of the binary mask present in Eq. (3) defined by

$$i_j^{ss} = \left\{ \frac{SSF(f_{w_j}^{\lambda_c}(u, v))}{A_{Mask_j}} \right\}. \quad (5)$$

Finally the spectral index of the image analyzed is obtained by averaging the indices computed as

$$\bar{i}^{ss} = \frac{1}{j} \sum_{j=1}^j i_j^{ss}. \quad (6)$$

## 3. Results

The methodology was applied to a set of 332 dermatologic images of different sizes provided by medical specialists. This image set contains images of skin cancer (260) and benign lesions (72). The classic, inverse and k-law nonlinear filter using different color transformation was applied to each image.

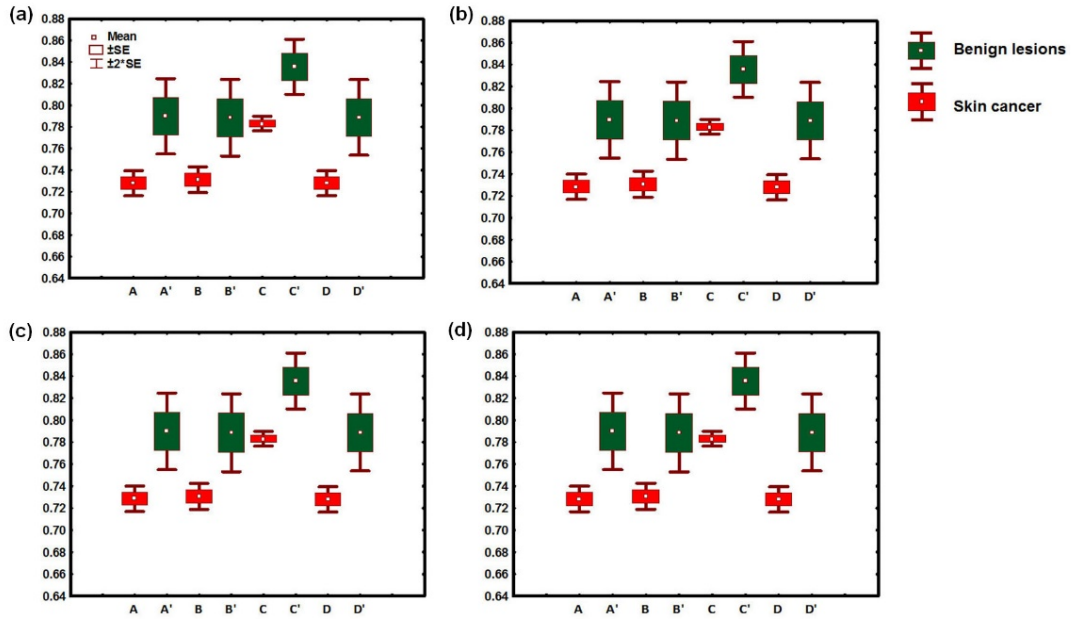


Fig. 6. Malignant-benign classification. Box plot of the spectral indices of k-law filter using RGB channels and grayscale: a) red channel, b) green channel, c) blue channel and d) grayscale images.

Figure 6 shows the boxplots of the spectral indices using the mean of the values with two standard errors ( $\pm 2SE$ ), using a k-law filter. Box plots in red color makes reference to images of skin cancer and box plots in green color indicates the conditions for benign lesions. We observe that there is not an overlap of the whiskers in each of the conditions for images of skin cancer and benign lesions. The different filters showed results very similar in all cases. Letters A, B, C and D show the used conditions for skin cancer and A', B', C' and D' show the used conditions for benign lesions (Table 1). In this figure all three categories of skin cancer defined above are considered.

Table 1. Conditions given for real and imaginary part

Cancer	Benign lesion	Conditions
A	A'	$Re(f_{w_j}^{\lambda_j}(u, v)) \geq 0$
B	B'	$Re(f_{w_j}^{\lambda_j}(u, v)) < 0$
C	C'	$Im(f_{w_j}^{\lambda_j}(u, v)) \geq 0$
D	D'	$Im(f_{w_j}^{\lambda_j}(u, v)) < 0$

Table 2 presents the intervals of spectral indices obtained by statistical analysis applying the k-law filter. In each channel it can be seen that there is a clear difference between the intervals obtained for skin cancer and lesion benign images, so the results shows that the both groups can be located in well-defined fringe. The classical and inverse filters were also analyzed obtaining the same values, this is due to the conditions applied over the spectral densities in each sub-image. This methodology has a confidence level of 95.4%.

**Table 2. Intervals**

Conditions	Intervals for skin cancer	Intervals for benign lesions
<b>R channel</b> $Re \geq 0$	0.7166 - 0.7393	0.7556 - 0.8239
<b>R channel</b> $Re < 0$	0.7195 - 0.7428	0.7538 - 0.8233
<b>R channel</b> $Im \geq 0$	0.7765 - 0.7897	0.8106 - 0.8605
<b>R channel</b> $Im < 0$	0.7167 - 0.7393	0.7544 - 0.8230
<b>G channel</b> $Re \geq 0$	0.7171 - 0.7397	0.7553 - 0.8237
<b>G channel</b> $Re < 0$	0.7190 - 0.7425	0.7541 - 0.8234
<b>G channel</b> $Im \geq 0$	0.7765 - 0.7897	0.8106 - 0.8605
<b>G channel</b> $Im < 0$	0.7167 - 0.7393	0.7544 - 0.8230
<b>B channel</b> $Re \geq 0$	0.7170 - 0.7399	0.7556 - 0.8239
<b>B channel</b> $Re < 0$	0.7190 - 0.7423	0.7538 - 0.8233
<b>B channel</b> $Im \geq 0$	0.7765 - 0.7897	0.8106 - 0.8605
<b>B channel</b> $Im < 0$	0.7167 - 0.7393	0.7544 - 0.8230
<b>Grayscale</b> $Re \geq 0$	0.7170 - 0.7397	0.7557 - 0.8240
<b>Grayscale</b> $Re < 0$	0.7191 - 0.7425	0.7537 - 0.8231
<b>Grayscale</b> $Im \geq 0$	0.7765 - 0.7897	0.8106 - 0.8605
<b>Grayscale</b> $Im < 0$	0.7167 - 0.7393	0.7544 - 0.8230

Considering now, separately different skin lesions like Basal cell carcinoma, Squamous cell carcinoma and Melanoma, Figs. 7, 8, and 9 show the boxplots of the spectral indices using the mean of the values with two standard errors, using a k-law filter. For Basal cell carcinoma 32 images, for Squamous cell carcinoma 30 images and for Melanoma 198 images were used. Again, we observe that there is not an overlap of the whiskers in each of the conditions for images of skin cancer and benign lesions. The different filters showed very similar results in all the cases. The range of values for the first two cancer types are a little lower when are compared with the range of values for melanoma. However, these well-defined fringes can be useful to determine the kind of skin cancer. The biological variability (hence the error bars) are much larger on benign than on malignant lesions. The main difference between Figs. 7 and 8 is the condition C (Table 1). Thus the results in the three channels and in the grayscale are very similar, the numerical differences can be observed in the Tables 3, 4, and 5.



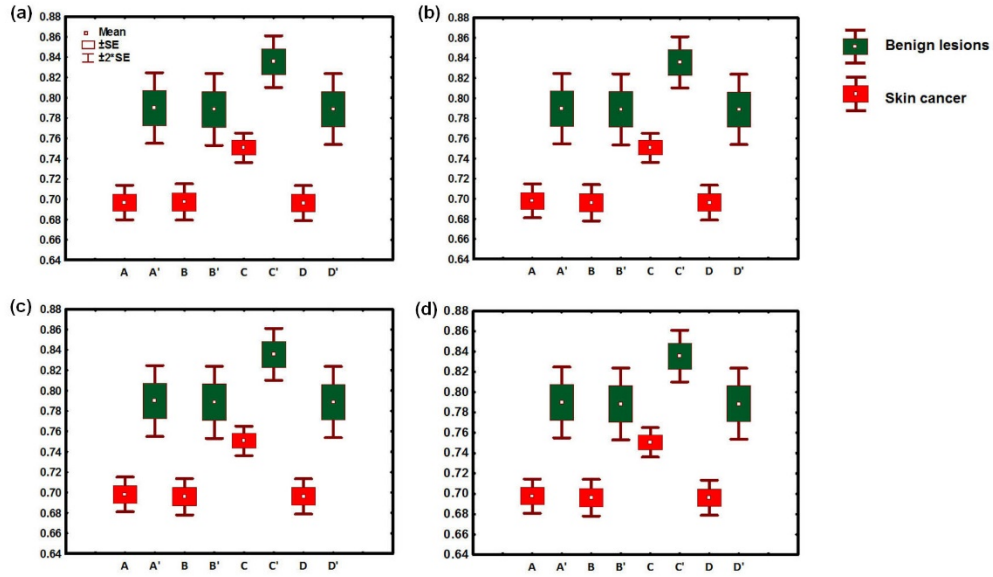


Fig. 7. Basal cell carcinoma. Box plot of the spectral indices of k-law filter using RGB channels and grayscale: a) red channel, b) green channel, c) blue channel and d) grayscale images.




Fig. 8. Squamous cell carcinoma. Box plot of the spectral indices of k-law filter using RGB channels and grayscale: a) red channel, b) green channel, c) blue channel and d) grayscale images.

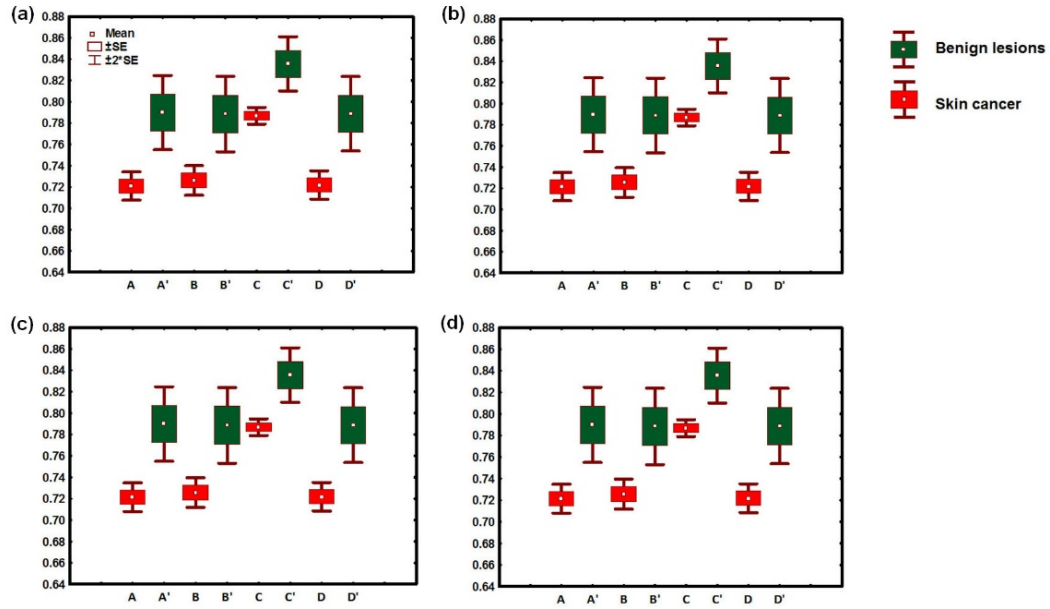


Fig. 9. Melanoma. Box plot of the spectral indices of k-law filter using RGB channels and grayscale: a) red channel, b) green channel, c) blue channel and d) grayscale images.

Table 3. Intervals

Conditions	Intervals for basal cell carcinoma	Intervals for benign lesions
<b>R channel</b> $Re \geq 0$	0.6796 - 0.7137	0.7550 - 0.8246
<b>R channel</b> $Re < 0$	0.6794 - 0.7151	0.7531 - 0.8240
<b>R channel</b> $Im \geq 0$	0.7361 - 0.7651	0.8101 - 0.8611
<b>R channel</b> $Im < 0$	0.6788 - 0.7133	0.7537 - 0.8237
<b>G channel</b> $Re \geq 0$	0.6811 - 0.7148	0.7546 - 0.8244
<b>G channel</b> $Re < 0$	0.6779 - 0.7140	0.7534 - 0.8242
<b>G channel</b> $Im \geq 0$	0.7361 - 0.7651	0.8101 - 0.8611
<b>G channel</b> $Im < 0$	0.6788 - 0.7133	0.7537 - 0.8237
<b>B channel</b> $Re \geq 0$	0.6810 - 0.7152	0.7549 - 0.8246
<b>B channel</b> $Re < 0$	0.6780 - 0.7136	0.7531 - 0.8240
<b>B channel</b> $Im \geq 0$	0.7361 - 0.7651	0.8101 - 0.8611
<b>B channel</b> $Im < 0$	0.6788 - 0.7133	0.7537 - 0.8237
<b>Grayscale</b> $Re \geq 0$	0.6808 - 0.7146	0.7550 - 0.8247
<b>Grayscale</b> $Re < 0$	0.6781 - 0.7143	0.7530 - 0.8239
<b>Grayscale</b> $Im \geq 0$	0.7361 - 0.7651	0.8101 - 0.8611
<b>Grayscale</b> $Im < 0$	0.6788 - 0.7133	0.7537 - 0.8237

**Table 4. Intervals**

Conditions	Intervals for squamous cell carcinoma	Intervals for benign lesions
<b>R channel</b> $Re \geq 0$	0.6705 - 0.7143	0.7556 - 0.8239
<b>R channel</b> $Re < 0$	0.6747 - 0.7194	0.7538 - 0.8233
<b>R channel</b> $Im \geq 0$	0.6732 - 0.7058	0.8106 - 0.8605
<b>R channel</b> $Im < 0$	0.6722 - 0.7162	0.7544 - 0.8230
<b>G channel</b> $Re \geq 0$	0.6708 - 0.7146	0.7553 - 0.8237
<b>G channel</b> $Re < 0$	0.6744 - 0.7191	0.7541 - 0.8234
<b>G channel</b> $Im \geq 0$	0.6732 - 0.7058	0.8106 - 0.8605
<b>G channel</b> $Im < 0$	0.6722 - 0.7162	0.7544 - 0.8230
<b>B channel</b> $Re \geq 0$	0.6710 - 0.7145	0.7556 - 0.8239
<b>B channel</b> $Re < 0$	0.6742 - 0.7193	0.7538 - 0.8233
<b>B channel</b> $Im \geq 0$	0.6732 - 0.7058	0.8106 - 0.8605
<b>B channel</b> $Im < 0$	0.6722 - 0.7162	0.7544 - 0.8230
<b>Grayscale</b> $Re \geq 0$	0.6709 - 0.7149	0.7557 - 0.8240
<b>Grayscale</b> $Re < 0$	0.6743 - 0.7189	0.7537 - 0.8231
<b>Grayscale</b> $Im \geq 0$	0.6732 - 0.7058	0.8106 - 0.8605
<b>Grayscale</b> $Im < 0$	0.6722 - 0.7162	0.7544 - 0.8230

**Table 5. Interval**

Conditions	Intervals for melanoma	Intervals for benign lesions
<b>R channel</b> $Re \geq 0$	0.7079 - 0.7340	0.7556 - 0.8239
<b>R channel</b> $Re < 0$	0.7125 - 0.7398	0.7538 - 0.8233
<b>R channel</b> $Im \geq 0$	0.7792 - 0.7945	0.8106 - 0.8605
<b>R channel</b> $Im < 0$	0.7087 - 0.7349	0.7544 - 0.8230
<b>G channel</b> $Re \geq 0$	0.7085 - 0.7347	0.7553 - 0.8237
<b>G channel</b> $Re < 0$	0.7118 - 0.7391	0.7541 - 0.8234
<b>G channel</b> $Im \geq 0$	0.7792 - 0.7945	0.8106 - 0.8605
<b>G channel</b> $Im < 0$	0.7087 - 0.7349	0.7544 - 0.8230
<b>B channel</b> $Re \geq 0$	0.7082 - 0.7346	0.7556 - 0.8239
<b>B channel</b> $Re < 0$	0.7121 - 0.7393	0.7538 - 0.8233
<b>B channel</b> $Im \geq 0$	0.7792 - 0.7945	0.8106 - 0.8605
<b>B channel</b> $Im < 0$	0.7087 - 0.7349	0.7544 - 0.8230
<b>Grayscale</b> $Re \geq 0$	0.7083 - 0.7345	0.7557 - 0.8240
<b>Grayscale</b> $Re < 0$	0.7121 - 0.7393	0.7537 - 0.8231
<b>Grayscale</b> $Im \geq 0$	0.7792 - 0.7945	0.8106 - 0.8605
<b>Grayscale</b> $Im < 0$	0.7087 - 0.7349	0.7544 - 0.8230

Table 6 shows a comparison about level of confidence with others works.

**Table 6. Comparison with other works**

Authors	Confidence level
Gola <i>et al.</i>	86%
Rahmana and P. Bhattacharya	72.45%
Cavalcanti and J. Scharcanski	94.54%
Jaleel <i>et al.</i>	Good accuracy
Sadegui <i>et al.</i>	94.3%
Barata <i>et al.</i>	82.1%
Betta <i>et al.</i>	Good accuracy
Celebi <i>et al.</i>	92.34%
Premaladha and Ravichandran	92%
This work	95.4%

#### 4. Conclusions

This paper presents a new methodology for the diagnosis of skin cancer on images with spots through a spectral analysis using different types of filters such as classic, inverse and k-law nonlinear, making a frequency analysis into the RGB and grayscale channels. The confidence level is of 95.4%.

After testing the filters the results obtained show a no significant difference, this is due to apply the conditions of the spectral density for obtaining the binarized image, therefore any filter on any channel can be used. Images of skin cancer and benign lesion were analyzed. The results show a clear difference between the intervals for the diagnosing of skin cancer and benign lesions. The results show that skin cancer presents a well-defined fringe of spectral indices, so the values obtained inside this fringe will be diagnosed as skin cancer.

It may be helpful for medical doctors who do not have enough experience in dermatology. Finally this system will provide a fast diagnosis for the medical field and it will be a non-invasive tool for the patient, therefore it can help prevent skin cancer

#### Appendix A

The image is intensity data set in the spatial domain, which is represented by the multispectral function  $f_w^{\lambda_c}(x, y)$  where every pixel coordinate  $x$  and  $y$  and  $\lambda_c = \{\lambda_R, \lambda_G, \lambda_B\}$  where red (R), green (G) and blue (B) are the channels represented by RGB color model produced by a digital image with a range of [0, 255].

The filter bank is made up of  $f_1^\lambda, f_2^\lambda, f_3^\lambda, \dots, f_w^\lambda$  multispectral functions,  $w$  is the image taken of size  $N \times P$  pixels where  $x = 1, \dots, N$ ,  $y = 1, \dots, P$ .

Each image  $f_w^{\lambda_c}(x, y)$  can be separated in their respective RGB channels, thus obtaining the data for three intensity matrices  $f_w^{\lambda_R}(x, y)$ ,  $f_w^{\lambda_G}(x, y)$  and  $f_w^{\lambda_B}(x, y)$ .

Every intensity matrix channel of skin cancer is analyzed by taking an intensity profile vector set  $\{\xi_q^\lambda\}_w$  where  $q = 1, \dots, Q$  vectors and  $\{\xi_q^\lambda\}_w \in f_w^{\lambda_c}(x, y)$ , thus  $\{\xi_q^\lambda\}_w$  can be defined by

$$\{\xi_q^\lambda\}_w = f_w^{\lambda_c}(x, \zeta_{V_t}), \text{ for } V_t = -\left[\frac{Q}{2}\right], \dots, \left[\frac{Q}{2}\right], \quad (7)$$

where  $V_t \in \mathbb{Z}$ ,  $\zeta_{V_t} = \left\lfloor \frac{N}{2} \right\rfloor + V_t$  and  $x = 1, \dots, P$ .

Let  $\hat{\Psi}^\lambda$  be a vector of mean values of intensity profile vector set, on each channel, where  $\hat{\Psi}^\lambda \in \mathbb{R}$ , using Eq. (7) these mean values can be calculated as

$$\hat{\Psi}_w^{\lambda_q} = \frac{\sum \{\xi_q^\lambda\}_w}{Q} \quad (8)$$

$Q = 30$  was the value taken in this study for all images. Figure 10 shows the intensity profile vector set  $\{\xi_q^\lambda\}_w$  with calculated graphics from each skin cancer channel using Eq. (7), afterwards, using Eq. (8) can be obtained the pattern measurement for every skin cancer channel  $\hat{\Psi}^{\lambda_R}$ ,  $\hat{\Psi}^{\lambda_G}$ ,  $\hat{\Psi}^{\lambda_B}$  and  $\hat{\Psi}^{Gray}$  respectively. The  $x$  axes represents the distance along profile

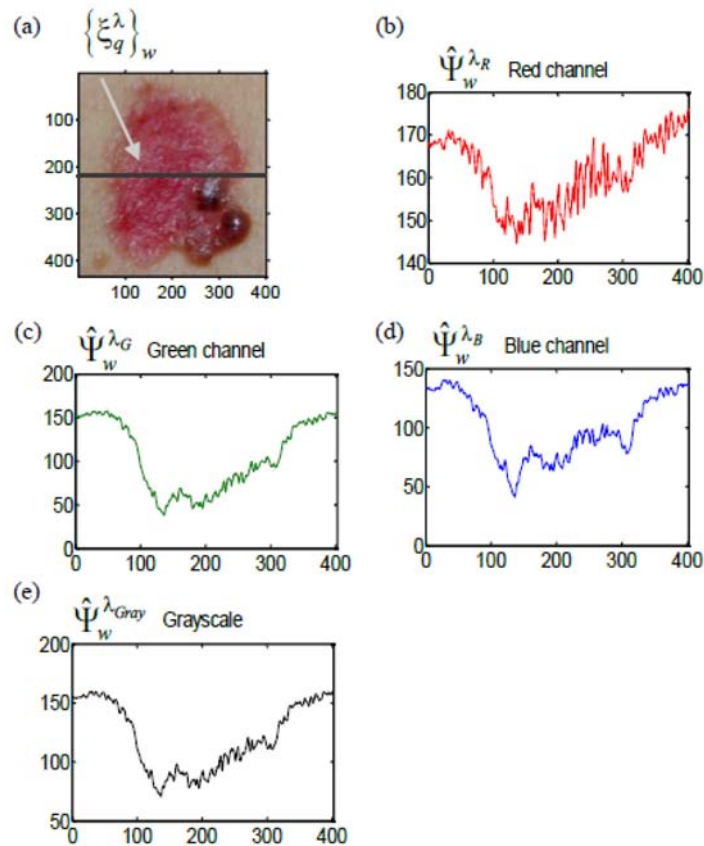


Fig. 10. Intensity profiles, (a) Intensity vector set, (b) mean values of red channel (c) mean values of green channel, (d) mean values of blue channel and (e) mean values of grayscale.

Fig. 11 shows all the intensity profiles, where a small difference between each intensity profile can be observed, however after applying the methodology the results do not present significant difference, thus any color channel or grayscale can be used.




Fig. 11. Intensity profiles of all channels and grayscale.

## Appendix B

Filters allow us to extract the interested information on an image, the methodology presented in this work is based on the classic, inverse and nonlinear k-law.

a) A classic filter [21] is denoted as

$$CF = \left| I_{w_j}^{\lambda_c}(u, v) \right| \exp \left[ j\varphi_{w_j}(u, v) \right], \quad (9)$$

where  $I_{w_j}^{\lambda_c}(u, v)$  is the Fourier transformation of the function  $I_{w_j}^{\lambda_c}(x, y)$  and  $\varphi_{w_j}(u, v)$  is the phase.

b) Inverse filter [22, 23] is defined as

$$IF = \frac{\exp \left[ -j\varphi_{w_j}(u, v) \right]}{\left| I_{w_j}^{\lambda_c}(u, v) \right|}. \quad (10)$$

c) A k-law nonlinear filter [24] is expressed as follows

$$k - lawF = \left| I_{w_j}^{\lambda_c}(u, v) \right|^k \exp \left[ j\varphi_{w_j}(u, v) \right], \quad (11)$$

Where  $\left| I_{w_j}^{\lambda_c}(u, v) \right|$  is the modulus of the Fourier transform and  $u, v$  are variables obtained in the frequency domain,  $k$  is the level of nonlinearity that takes values  $0 < k < 1$ ,  $\varphi_{w_j}(u, v)$  is the phase of the Fourier transform. The nonlinearity factor  $k = 0.1$  was used.

Then each filter was applied over the function  $I_{w_j}^{\lambda_c}(x, y)$  to obtain the function for each filter respectively.

## Acknowledgments

This document is based on work partially supported by CONACYT under grant No. 169274 and partially supported by Centro de Investigación Científica y de Educación Superior de Ensenada (CICESE). Esperanza Guerra-Rosas is a student in the PhD Departamento de Investigación en Física offered by Universidad de Sonora and supported by CONACYT's scholarship.

# Diagnosis of Skin Cancer Using Image Processing

Esperanza Guerra-Rosas<sup>a</sup>, Josué Álvarez-Borrego<sup>b</sup>, Ángel Coronel-Beltrán<sup>a</sup>

<sup>a</sup>Departamento de Investigación en Física, Universidad de Sonora (UNISON), Luis Encinas y Rosales S/N, Col. Centro, Hermosillo, Sonora, México C.P. 83000

<sup>b</sup>Centro de Investigación Científica y de Educación Superior de Ensenada (CICESE), División de Física Aplicada, Departamento de Óptica, Carretera Ensenada-Tijuana No. 3918, Fraccionamiento Zona Playitas, Ensenada, Baja California, México C.P. 22860


**Abstract.** In this paper a methodology for classifying skin cancer in images of dermatologic spots based on spectral analysis using the  $K$ -law Fourier non-linear technique is presented. The image is segmented and binarized to build the function that contains the interest area. The image is divided into their respective RGB channels to obtain the spectral properties of each channel. The green channel contains more information and therefore this channel is always chosen. This information is point to point multiplied by a binary mask and to this result a Fourier transform is applied written in nonlinear form. If the real part of this spectrum is positive, the spectral density take unit values, otherwise are zero. Finally the ratio of the sum of the unit values of the spectral density with the sum of values of the binary mask are calculated. This ratio is called spectral index. When the value calculated is in the spectral index range three types of cancer can be detected. Values found out of this range are benign injure.

**Keywords:** Skin cancer, image processing techniques, spectral index.

**PACS:**87.19.xj,42.30.Kq,42.30.Va

## INTRODUCTION

One of the diseases that affect the humans is the skin cancer. Skin cancer is a disease that is caused by the development of cancerous cells in any of skin layers. In the last decades has been detected a great increase in this disease. There are two types of skin cancer: the non-melanoma and melanoma. Melanoma is the skin cancer more dangerous [1], (Fig.1). Skin cancer, in their most common forms are the malignant melanoma, the basal cell carcinoma and squamous cell carcinoma [2]. Cancer cells grow and divide in an uncontrolled manner and may invade and damage nearby tissues and organs. When the skin cancer is not detected in time can spread from the skin to other organs, producing the death [3]. Within the non-melanoma can be found basal cell carcinoma and squamous cell carcinoma. There are of course other malignant tumors in the skin like carcinomas of sebaceous glands, sweat, sarcomas, or cutaneous manifestations of internal malignancies, but are rare [4]. The skin cancer represents at the present, a serious health problem, the search for an accurate clinical diagnosis of skin tumors has been a constant concern of dermatologists. Fig. 2 shows some images of each of the types of cancer referred above.



**FIGURE 1.** Distribution of melanoma.

In this paper we present a method of identification skin cancer in images with spots, making to an analysis based in the application of Fourier spectral filtering techniques, such as  $K$ -law nonlinear filter technique.

Corresponding author: josue@cicese.mx



**FIGURE 2.** (a) Basal cell carcinoma, group I; (b) Squamous cell carcinoma, group II; (c) Melanoma, group III; (d) Benign lesions, group IV.

The main objective of this paper is to develop an algorithm based on image processing technique, for the classification and detection of skin spots, with the aim of providing a tool for the diagnosis of a particular disease. To get the image, the operator may be recaptured, and using the algorithm you can easily analyze it or classify it.

This article is written as follows: First the materials and methods used to obtain the spectral index in images of different type of skin cancer is described; after the results obtained with the algorithm of spectral index are shown; finally the conclusions and future work are presented.

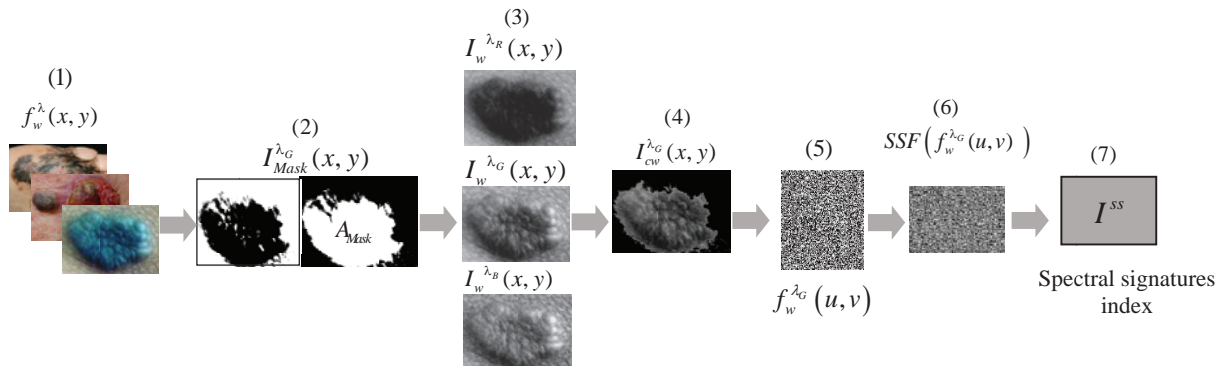
## MATERIALS AND METHODS

Section A describes the image acquisition and construction of the filter bank; section B describes the steps involved to obtain the classification of spectral indices. Fig. 3 shows the block diagram to obtain spectral index.

### A. Image acquisition and construction of the filter bank.

The images were provided by the Centenario Hospital Hidalgo, Aguascalientes, Ags., and of the Instituto Nacional de Cancerología (INCan) México City, the filter bank was constructed with the images of which are manually selected only the stain to be analyzed.

### B. Block diagram to obtain the spectral index.



**FIGURE 3.** Block diagram to obtain the spectral index.



*Step 1.* The sample image is taken of the filter bank to be analyzed in the spatial domain  $f_w^\lambda(x, y)$ , which is the captured image matrix with pixels  $(x, y)$ . *Step 2.* The image is segmented and binarized to build the function  $I_{Mask}^{\lambda_G}(x, y)$ , that contains the area of the segmented image, where we define  $(A_{Mask})_w$  such as the binary mask's total area over the region of interest analyzed, for each  $w$  image filter defined by

$$(A_{Mask})_w = \sum_w \sum_{x,y} I_{Mask}^{\lambda_G}(x, y), \text{ for } I_{Mask}^{\lambda_G}(x, y) > 0. \quad (1)$$

*Step 3.* The image is divided into their respective RGB channels  $I_w^{\lambda_R}(x, y), I_w^{\lambda_G}(x, y), I_w^{\lambda_B}(x, y)$ , to obtain the spectral properties of each channel, it takes a function  $I_w^{\lambda_G}(x, y)$  (always the green channel is chosen). *Step 4.* to apply the  $I_{Mask}^{\lambda_G}(x, y)$  binary mask function to the function  $I_w^{\lambda_G}(x, y)$  to analyze the area, gets  $I_{cw}^{\lambda_G}(x, y)$  function, this is the matrix obtained from intensity data that contains the characteristics of the wound. Then  $I_{cw}^{\lambda_G}(x, y) = I_w^{\lambda_G}(x, y) \wedge I_{Mask}^{\lambda_G}(x, y)$ , where  $\wedge$  represents a point to point multiplication. *Step 5.* to this function is applied the Fourier Transform,  $f_w^{\lambda_G}(u, v) = \mathfrak{F}(I_{cw}^{\lambda_G}(x, y))$  which can be writing in nonlinear form with a strength factor  $K=0.1$ . Of this manner the function  $f_w^{\lambda_G}(u, v)$ , in the frequency domain is denoted by,

$$f_w^{\lambda_G}(u, v) = |f_w^{\lambda_G}(u, v)|^K \exp[-i\phi(u, v)], \quad K = 0.1. \quad (2)$$

In *Step 6* the frequencies extracted of  $f_w^{\lambda_G}(u, v)$  are analyzed, so the spectral density is obtained by

$$SSF(f_w^{\lambda_G}(u, v)) = \begin{cases} 1 & \text{if } \text{Re}(f_w^{\lambda_G}(u, v)) > 0 \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

Finally the spectral index is obtained by ratio of the sum of the unit values present in the step 6 and the sum of the unit values present in the step 2 defined by, *Step 7*

$$i^{ss} = \frac{SSF(f_w^{\lambda_G}(u, v))}{(A_{Mask})_w} \quad (4)$$


## RESULTS

We analyzed images of the different types of cancer: basal cell carcinoma, squamous cell carcinoma and melanoma, benign lesions were also analyzed. Some of these images are shown in Fig. 2. Table 1 shows the range of values obtained for each type of cancer. When the value calculated is in the spectral index range three types of cancer can be detected. Values found out of this spectral range are benign injury.

**TABLE 1.** Ranges of spectral indices for each type of cancer.

Type of cancer	Spectral Range
Basal cell carcinoma	$0.9388 \leq i^{ss} \leq 1.2399$
Squamous cell carcinoma	$0.7765 \leq i^{ss} \leq 1.0075$
Melanoma	$0.9832 \leq i^{ss} \leq 1.8236$

Fig. 4 shows a few examples of the spectral densities obtained for each group of cancer.



**FIGURE 4.** (A) Spectral density of the group of basal cell carcinoma; (b) Spectral density of the group of squamous cell carcinoma; (c) Spectral density of the group of Melanoma; (d) Spectral density of benign lesions.

Hence in table 1 the statistical behavior values of the spectral signature index are shown, where it was used the test t-student.

## CONCLUSIONS AND FUTURE WORK

This paper presents a new technique for identifying skin cancer based on analysis of frequencies found in the green channel with a law nonlinear filter. We analyzed the different types of skin cancer (basal cell carcinoma, squamous cell carcinoma and melanoma), introducing different range of classification for each type. Future work can be develop an automatic diagnosis system of skin cancer by applying this technique of spectral index

## ACKNOWLEDGMENT

This document is based on work partially supported by CONACYT under Grant No. 102007 and 169274. Esperanza Guerra-Rosas is a student in the PhD in Physical Sciences by Universidad de Sonora and supported by CONACYT's scholarship.

## REFERENCES

1. M. Saraiya, I. Hall, T. Thompson, A. Hartman, K. Glanz, B. Rimer and D. Rose, *ELSEVIER*, Skin cancer screening among U.S. adults from 1992, 1998, and 2000 National Health Interview Surveys, 2004, pp. 308-314.
2. W. F. Benitez, C.F. Basulda, and C.B. de los Reyes, *Revista de posgrado de la Via Cátedra de medicina* Cáncer de piel: Principales aspectos epidemiológicos en el hospital escuela "José Francisco de San Martín", No. 155, March 2006.
3. U. P. Hegde, and J.M Grant-Kels, *ELSEVIER*, Ethical issues in cutaneous melanoma, 2012, pp. 501-510.
4. R. M. Gutiérrez, *RevFacMed UNAM*, Cáncer de piel, Vol.4, 2003, pp. 166-171.