

Universidad Central de Venezuela
Facultad de Ciencias
Escuela de Física



**Análisis de Escalamiento de
Interfaces Lesión-Tejido
*para lesiones de piel***

Trabajo Especial de Grado presentado por
John Frank García Key
ante la Facultad de Ciencias de la
Ilustre Universidad Central de Venezuela
Como requisito parcial para optar al título
de: **Licenciado en Física**

Con la tutoría de: Dr. Miguel Martín Landrove

Marzo de 2015
Caracas - Venezuela

Universidad Central de Venezuela
Facultad de Ciencias
Escuela de Física



Análisis de Escalamiento de Interfaces Lesión-Tejido *para lesiones de piel*

Trabajo Especial de Grado presentado por
John Frank García Key
ante la Facultad de Ciencias de la
Ilustre Universidad Central de Venezuela
Como requisito parcial para optar al título
de: **Licenciado en Física**

Con la tutoría de: Dr. Miguel Martín Landrove

Marzo de 2015
Caracas - Venezuela

Análisis de Escalamiento de Interfaces Lesión-Tejido *para lesiones de piel*

Copyright © 2015

Universidad Central de Venezuela
John F. García K.

Caracas, Marzo del 2015

Análisis de Escalamiento de Interfaces Tumor- Tejido *para lesiones de piel*

Br. John Frank García Key

Trabajo Especial de Grado presentado
Ante la ilustre Facultad de Ciencias de la
Universidad Central de Venezuela como
Requisito parcial para optar al título de:

Licenciado en Física.

Dr. Miguel Martín Landrove, Tutor.

AGRADECIMIENTOS

A Jehová mi Dios, quien me ha dado la vida y luego me salvó por medio de su Hijo Jesucristo, y me llamó por su gracia y me dio la fuerza y el ánimo de terminar esta faceta de mi vida.

A mis padres por haber sido tan pacientes en la espera de esta meta y me han apoyado incondicionalmente. A mi padre Francisco Anselmo García Ayala, fallecido este mismo mes a quien le dedico esta tesis pues es él quien más insistió en animarme a culminar esta etapa de mi vida. A mi madre Mireya Key, quien siempre me apoya y por eso la amo mucho.

A mi hermano Werner García quien fue mi primer mentor y guía para estudiar física.

A mi esposa Migdalia Carpio y a mis hijas Deborah García y Nicole García por apoyarme y mostrarme que me aman sin importar nada.

Resumen

Análisis de Escalamiento de Interfaces Lesión-Tejido *para lesiones de piel*

John F. García K.
Dr. Miguel Martín Landrove Tutor
Universidad Central de Venezuela

Para un dermatólogo su objetivo principal es el análisis de las lesiones de piel y determinar la malignidad en cada caso. Para ello usa el dermatoscopio que le ayuda en un mejor diagnóstico visual de dichas lesiones. Con este aparato se puede visualizar las estructuras presentes en las diferentes capas de la piel. El ojo especializado sin embargo posee un alto grado de subjetividad que incide en la diversidad de diagnósticos a partir de una misma imagen de una lesión. Además las lesiones de piel presentan una frontera irregular cuyas propiedades varían según si son benignas o malignas. Para evaluar de forma apropiada esta irregularidad es necesario aplicar metodologías de segmentación de imágenes que permitan definir claramente la frontera de la lesión. En el presente trabajo se utilizó un conjunto de 20 imágenes adquiridas en pacientes que consultaron por lesiones pigmentadas en la piel y que fueron referidas para la captura de las imágenes con un dermatoscopio. Las imágenes fueron segmentadas y se determinaron los contornos de las lesiones. Varias propiedades fractales se determinaron sobre el contorno: la dimensión fractal o de capacidad, y también un exponente crítico proveniente de la rugosidad del contorno. Los resultados obtenidos demuestran la buena correlación entre el exponente crítico asociado a la rugosidad del contorno y el grado de malignidad de la lesión.

Índice General

Lista de Figuras.....	p. 11
Introducción.....	p. 14
Objetivos.....	p. 17
1. Capítulo 1	
1.1 Lesiones de Piel.....	p. 19
1.2 Algoritmos Diagnósticos.....	p. 19
1.3 Métodos Cuantitativos.....	p. 20
1.3.1 Análisis de Patrones.....	p. 20
1.4 Métodos Semicuantitativos.....	p. 22
1.4.1 ABCD de Stolz.....	p. 22
1.4.2 Los 7 puntos de Argenziano.....	p. 23
1.4.3 Método de Menzies.....	p. 24
2 Capítulo 2.....	p. 25
2.1 Imagen Digital.....	p. 25
2.2 Color de la Imagen Digital.....	p. 26
2.3 Resolución de la Imagen Digital.....	p. 26
2.4 Formatos de la Imagen Digital.....	p. 27
2.5 Tipos de Imagen de Datos.....	p. 27
2.6 Espacios de Color.....	p. 28
2.7 Formación de la Imagen.....	p. 34
2.8 Realce de Imágenes.....	p. 40
2.9 Realce de Bordos.....	p. 50
2.10 Procesos Morfológicos.....	p. 51
2.11 Segmentación de Imágenes.....	p. 53
2.12 Tipos de Segmentación.....	p. 56
3 Capítulo 3	
3.1 Dinámica Física de los Crecimientos tumorales y Análisis de Escalamiento.....	p. 61
3.2 Análisis de Escalamiento.....	p. 63
4 Capítulo 4. Metodología.....	p. 67
4.1 Adquisición de las Imágenes.....	p. 67
4.2 Pre procesamiento – Segmentación.....	p. 68
4.3 Procesamiento – Obtención de Borde.....	p. 69
4.4 Calculo de la Dimensión Fractal.....	p. 70
4.5 Análisis de Escalamiento.....	p. 72
4.6 Validación del método de cálculo.....	p. 74
Capítulo 5	
RESULTADOS Y DISCUSIÓN.....	p. 79
CONCLUSIONES.....	p. 93
RECOMENDACIONES.....	p. 95

APÉNDICE	p. 97
Apéndice I. Algoritmo para hallar el borde la lesión binaria.....	p. 97
Apéndice II. Algoritmo para aplicar el script anterior.....	p. 98
Apéndice III. Algoritmo para hallar la dimensión fractal.....	p. 99
Apéndice IV. Algoritmo para hallar “W”, el ancho de la dispersión de la lesión.....	p. 103
Apéndice V. Algoritmo para hallar el factor de correlación de las curvas.....	p. 105
Apéndice VI. Algoritmo para hallar la dimensión fractal de los círculos de prueba para el método de validación.....	p. 106
BIBLIOGRAFÍA.....	p. 107

LISTA DE FIGURAS

Figura 1: Una representación gráfica de una lesión de piel con sus respectivos pixeles...	p. 25
Figura 2: El Cubo RGB modelo de representación gráfica del espacio de color RGB.....	p. 28
Figura 3: Lesión de piel separa en los tres canales de color RGB respectivamente.....	p. 29
Figura 4: Lesión de piel presentada en RGB y luego convertida a escala de grises respectivamente.....	p. 31
Figura 5: Representación Gráfica del espacio de color HSV.....	p. 32
Figura 6: Lesión de piel presentada en RGB y luego separa en los tres canales de HSV respectivamente.....	p. 33
Figura 7: Una visión general del sistema de formación de imagen y el efecto del PSF....	p. 34
Figura 8: Una explicación gráfica de la convolución.....	p. 35
Figura 9: Una imagen ampliada donde se logran ver los pixeles.....	p. 36
Figura 10: Lesión de piel en original comparada con la misma imagen sumada a un valor de 100.....	p. 36
Figura 11: Dos lesiones de piel sumadas.....	p. 37
Figura 12: La lesión de piel “foto 3” multiplicada por 1,5 y dividida entre 4 respectivamente.....	p. 37
Figura 13: La lesión de piel “foto 3”, luego convertida en blanco y negro (image bw) y luego negada usando el operador NOT respectivamente.....	p. 38
Figura 14: La lesión de piel “foto 3” y “foto 6”, luego de convertida en blanco y negro son sumadas y se le aplican los operadores OR, XOR y AND respectivamente.....	p. 38
Figura 15: La lesión de piel “foto 3” y su respectivo histograma.....	p. 39
Figura 16: Vecindades de un pixel de 4 y 8 pixeles.....	p. 40
Figura 17: Foto 3 original con ruido “salt and pepper” y con ruido “gaussiano” respectivamente.....	p. 42
Figura 18: Foto 3 original filtrada, luego con ruido “salt and pepper” filtrado y con ruido “gaussiano” filtrado respectivamente.....	p. 42
Figura 19: Foto 3 original con ruido “salt and pepper” y con ruido “gaussiano” y luego filtradas con mediana, con SP mediana y gaussiana filtro mediana respectivamente.....	p. 43
Figura 20: Foto 3 original con “filtro de rango”, luego con “salt and pepper” con filtro de rango y con ruido “gaussiano” con filtro de rango respectivamente.....	p. 44
Figura 21: Foto 3 original con “filtro gaussiano” en sus tres versiones respectivamente...	p. 46
Figura 22: Foto 8 (lesión 8) original segmentada, luego bajo el operador Roberts Edges, luego Prewitt Edges y finalmente bajo Sobel Edges respectivamente.....	p. 48

Figura 23: Foto 3 en escala de grises y luego con LoG Filter respectivamente.....	p. 49
Figura 24: Foto 3 en escala de grises y luego con el perfilado y el Laplaciano de bordes respectivamente.....	p. 50
Figura 25: Imagen binaria original y dilatada respectivamente.....	p. 52
Figura 26: Imagen binaria original y erosionada respectivamente.....	p. 52
Figura 27: Foto 8 segmentada en binaria original y luego la original erosionada usando un disco de radio 15 como elemento estructurante. Por último, la imagen original restada a la erosionada respectivamente.....	p. 53
Figura 28: Imagen original, luego con umbralización manual, polinómica y por el método Otsu respectivamente.....	p. 54
Figura 29: Foto 3 en original, luego en blanco y negro y luego en división y respectivamente.....	p. 56
Figura 30: Explicación gráfica de cómo funciona la segmentación por Watershed.....	p. 56
Figura 31: Calculo directo del operador Watershed sobre el gradiente de imágenes resultando en sobre segmentación.....	p. 57
Figura 32: Ejemplo gráfico de cómo opera el algoritmo del K-means para la segmentación.....	p. 59
Figura 33: Foto dermatoscópica de la lesión de piel del paciente 8, 7, 14 y 19 respectivamente.....	p. 67
Figura 34: Detección de pelos y enmascaramiento después de aplicar el filtro morfológico Bottom-Hat.....	p. 68
Figura 35: Diagrama de Flujo para el algoritmo especial de detección de la interface tumor-huésped. Los píxeles son aceptados cuando: el pixel central de la máscara de filtro 3x3, pertenece a la imagen segmentada y la suma S sea menor que 9.....	p. 69
Figura 36. a) Imagen Binaria de la lesión 14 segmentada y b) borde calculado de la interface del tumor calculado a partir del algoritmo presentado en este trabajo.....	p. 70
Figura 37 Dimensión Fractal obtenida para la lesión de piel n°14 calculada con el algoritmo de conteo de cajas, N (e) es el número de cajas y “e” es el tamaño de dicha caja. El valor obtenido para la dimensión fractal es $df= 1,018$	p. 71
Figura 38 Ancho de la Interface de un tumor-huésped.....	p. 72
Figura 39 Comportamiento de W (l) como está descrito en la ecuación 4.4.....	p. 73
Figura 40 Comportamiento de W (l) con el arco de longitud subtendido por los puntos de la interface de los círculos de muestra.....	p. 74
Figura 41 Comportamiento de df (dimensión fractal) subtendido por los puntos de la interface de los círculos de muestra.....	p. 76
Figura 42 Foto de la lesión 2 como representativa del Grupo A de lesiones de piel, b) Imagen binaria que es la segmentación de la foto a) y c) Borde extraído de la lesión 2 para análisis de escalamiento.....	p. 79
Figura 43 Comportamiento de df (dimensión fractal) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo A.....	p. 80
Figura 44 Comportamiento de α_{loc} (exponente de rugosidad) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo A.....	p. 81
Figura 45 Foto de la lesión 7 como representativa del Grupo B de lesiones de piel, b) Imagen binaria que es la segmentación de la foto a) y c) Borde extraído de la lesión 7 para análisis de escalamiento.....	p. 82

Figura 46 Comportamiento de df (dimensión fractal) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo B.....	p. 83
Figura 47 Comportamiento de α_{loc} (exponente de rugosidad) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo B.....	p. 84
Figura 48 Foto de la lesión 15 como representativa del Grupo C de lesiones de piel, b) Imagen binaria que es la segmentación de la foto a) y c) Borde extraído de la lesión 15 para análisis de escalamiento.....	p. 85
Figura 49 Comportamiento de df (dimensión fractal) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo C.....	p. 86
Figura 50 Comportamiento de α_{loc} (exponente de rugosidad) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo C.....	p. 87
Figura 51 Foto de la lesión 19 como representativa del Grupo C de lesiones de piel, b) Imagen binaria que es la segmentación de la foto a) y c) Borde extraído de la lesión 19 para análisis de escalamiento.....	p. 88
Figura 52 Comportamiento de df (dimensión fractal) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo D.....	p. 89
Figura 53 Comportamiento de α_{loc} (exponente de rugosidad) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo D.....	p. 90
Tabla 1: Lesiones de Piel. Caracterización de la Interface.....	p. 91

INTRODUCCIÓN

El crecimiento del tumor es un proceso complejo y que depende principalmente sobre la proliferación y la expansión de las células tumorales en los tejidos del huésped. Como muchas colonias naturales, las colonias de células parecen ser fractales y la descripción de la complejidad de su contorno usando geometría clásica Euclidiana es muy difícil. Sin embargo, la naturaleza fractal del contorno permite un análisis de escalamiento para caracterizar su comportamiento dinámico y por consiguiente ser usado para determinar el crecimiento tumoral o la progresión. Recientes estudios *in vitro* de colonias de células tumorales y secciones disectadas de tumores demuestran que alguna clase de universalidad en la dinámica del crecimiento tumoral puede ser determinada a través de la evaluación de las propiedades fractales y exponentes críticos (Martín Landrove, et al., 2008). Esto mismo se ha estudiado *in vivo* en las lesiones o tumores de piel.

El Melanoma Maligno (MM) es un tumor que deriva de células pigmentadas llamadas melanocitos, y su incidencia se ha incrementado rápidamente en las últimas cinco décadas. También, el MM responde pobremente a las terapias comúnmente disponibles, y es aún responsable por más de 75 % de todas las muertes por cáncer de piel. La exacta discriminación entre el MM y otra no maligna lesión pigmentada de piel (llamadas naevi melanocítico), y, aún más significativamente, la temprana detección de delgados MMs, es de mucha importancia para sobrevivir esta enfermedad. En la práctica corriente, el diagnóstico del MM es guiado por la regla del ABCD, basada en la evaluación de cuatro características morfológicas de la lesión: Asimetría, Irregularidad del borde, Variación del color, y el Diámetro de más de 5 mm. La sensibilidad de este diagnóstico clínico de MM es sólo del 65 al 80 %. No se reconoce pequeños MMs (menos que 5 mm de diámetro) y no son contados para una temprana MMs que podrían tener una forma regular y una distribución homogénea del color. En las últimas décadas, la actividad investigativa ha sido guiada por la necesidad de mejorar la certeza del diagnóstico.

La microscopía de epiluminiscencia (ELM) ha entrado en la práctica clínica diaria. ELM es una técnica no invasiva *in vivo*, que ha ampliado nuestras posibilidades de evaluar un número de características morfológicas normalmente invisible al ojo desnudo. Esto mejora la certeza del diagnóstico entre benigno versus maligno en lesiones de piel pigmentadas. Basado

sobre la posibilidad de analizar elementos estructurales normalmente ocultos al ojo desnudo (tales como, red de pigmentación, puntos negros, glóbulos, difusión radial de las venas, velos blancos/azules, pseudópodos, falsas red, etc.), un número de algoritmos para el diagnóstico han sido desarrollados para servir como guía al correcto diagnóstico, tales como análisis de patrones, la regla del ABCD, el método de Menzies, la lista de los siete puntos, y la lista modificada de puntos ABC. Sin embargo, la certeza del diagnóstico de tales metodologías analógicas está muy lejos del deseable 100%. El mejor diagnóstico reportado en la literatura muestra de hecho una tasa de sensibilidad del 90 %. Un límite de la dermatoscopia así como de todo diagnóstico clínico es que ellos están basados en la observación humana del color y la forma y esta evaluación está sujeta a la experiencia y la experticia del médico [1].

Ha sido descubierto empíricamente que los médicos tienen dificultades en la evaluación visual de las irregularidades en el borde de los contornos de las lesiones de piel y que sus evaluaciones no son invariantes a la reflexión y la rotación. Muchas investigaciones sobre medidas cuantitativas de la irregularidad han sido hechas para vencer estas limitaciones [2]. Se han desarrollado recientemente sistemas dermatoscópicos basados en computadora y tecnología electro-ópticas. El objetivo ha sido identificar algunas características y parámetros comunes en el análisis de lesiones de piel, y el objetivo final es el organizar un completo y automático dispositivo de diagnóstico teniendo la capacidad de diagnosticar lesiones pigmentadas fuera de la intervención de algún experto humano.

La técnica de segmentación es utilizada en imágenes computarizadas para separar la lesión del tejido normal de alrededor. Lesiones segmentadas que tienen la potencialidad de ser diferenciadas como benignas respecto a las lesiones cutáneas pigmentadas, son finalmente identificadas. Los sistemas de análisis de imágenes computarizadas son un interesante y prometedor campo de investigación. En perspectiva, tales sistemas juegan un importante rol como ayuda en el examen clínico y dermatoscópico. Para estos sistemas hay una característica que debe ser tomada en consideración en el intento de organizar un valioso método para el diagnóstico del melanoma y es la dimensión fractal [1] & [2].

El propósito de este trabajo es obtener parámetros y exponentes críticos del contorno de las lesiones de piel obtenidas por dermatoscopia en orden de determinar una posible correlación entre estos parámetros y la malignidad de la lesión. El problema envuelve la segmentación de la imagen de la lesión, con una posterior obtención del borde y el cálculo de la dimensión

fractal y el exponente crítico correspondiente a la rugosidad del contorno. También envuelve una validación del método de cálculo y una posterior comprobación de que la dimensión fractal obtenida sumada con el exponente de rugosidad da como resultado la dimensión euclídea.

Este trabajo está organizado de la siguiente manera. En el **Capítulo 1** se trata del tema de las lesiones de piel, su definición y su clasificación desde la lesión benigna hasta la maligna. Luego se procede a explicar con detalle los diferentes métodos de diagnóstico del Melanoma. En el **Capítulo 2** se aborda todo lo referente a lo que es la imagen digital y sus propiedades o características, también se explican los espacios de color y todo lo referente al tratamiento de las imágenes. Luego se procede a dar a conocer todo lo referente a los procesos morfológicos de la imagen así como también lo que es la segmentación. En este punto se explican los diversos tipos de segmentación que hay que más tarde serán usados en las imágenes dermatoscópicas. En el **Capítulo 3** entramos en la física de los crecimientos donde se presentan los diversos modelos de crecimiento celular y tumoral. También se explica en este capítulo todos los avances obtenidos en el análisis de escalamiento y obtención de los exponentes críticos geométricos y temporales que nos ayudan a tener una comprensión de la dinámica del crecimiento tumoral. El **Capítulo 4** presenta la metodología. Se discute aquí la selección de los datos de imágenes, así como el algoritmo de segmentación utilizado en el procesamiento de las imágenes y la obtención del borde con sus respectivos datos. También se explica el algoritmo usado para la obtención de la dimensión fractal del borde la lesión de piel y la herramienta usada para verificar la precisión de la dimensión fractal obtenida. También se explica el cálculo del exponente de rugosidad local de la interface de la lesión, así como la comprobación de que la suma de la dimensión fractal con el exponente de rugosidad nos da la dimensión euclídea respectiva. En el **Capítulo 5** se discute una validación del método de cálculo con énfasis en el tamaño de la data e imágenes de ejemplo. Los resultados y su discusión son presentados en el **Capítulo 6**. Las conclusiones y recomendaciones en el **Capítulo 7**.

Objetivos

Objetivos de la TEG

- Desarrollar diversos métodos de segmentación de imágenes de lesiones de piel en 2D.
- Realizar análisis de escalamiento de interfaces lesión-tejido en cada caso de segmentación utilizado.

Objetivos Específicos

- Obtendremos diversas imágenes 2D de las lesiones de piel.
- Segmentaremos dichas imágenes por diferentes métodos basados en el análisis de histograma y morfología matemática.
- Se pasará a realizar el análisis de escalamiento para la interface lesión-tejido tanto si es clínico como si es subclínico.
- Se compararán los resultados cuando esto sea posible.

MARCO TEÓRICO

Exposición de la Teoría Involucrada

- Clasificación de las lesiones de piel y métodos tradicionales de diagnóstico.
- Segmentación de Imágenes.
- Segmentación por análisis de histogramas.
- Segmentación por morfología matemática.
- Física de los crecimientos tumorales.
- Análisis de escalamiento.

Capítulo 1

1.1 Lesiones de Piel

Las lesiones de piel pueden ser agrupadas en tres clases [3]:

- ✓ *Nevi benigno*: es un nombre común para las lesiones de piel saludables. Estas no incrementan el riesgo de desarrollar cáncer.
- ✓ *Nevi Atípico*: es también una lesión de piel originalmente benigna, pero tiene un incremento del riesgo de convertirse en lesiones cancerosas. El tipo especial de nevi atípico llamado nevi displásico tiene un alto riesgo y es, por tanto, frecuentemente referido como el precursor del melanoma maligno.
- ✓ *Melanoma maligno*: se refiere a él comúnmente como lesiones cancerosas de piel.

El melanoma es un tumor maligno originado a partir de los melanocitos epidérmicos. Según datos estadísticos la incidencia del melanoma ha aumentado drásticamente y el diagnóstico por parte de los dermatólogos se estima que no es mayor del 80%. Esto hace que sea de mucha importancia el diagnóstico precoz del melanoma para la supervivencia del paciente afectado. La dermatoscopia logra una sensibilidad del 92% de modo que abre una oportunidad en la caracterización de las lesiones de piel pues permite ver las estructuras presentes y muchas otras cosas que son invisibles a ojo desnudo.

1.2 Algoritmos para el Diagnóstico

Veamos un poco los algoritmos diagnósticos más importantes que intentan facilitar el diagnóstico dermatoscópico del melanoma. El consenso logrado en el año 2000 por Argenziano y Soyer para el procedimiento diagnóstico se le llama “el método de las dos etapas” [4]. Ante una lesión pigmentada, en primer lugar (primera etapa) el médico debe discernir si se encuentra ante una lesión melanocítica o no melanocítica. Posteriormente (segunda etapa) debe distinguir la naturaleza benigna o maligna de la lesión melanocítica en cuestión. Para la primera etapa reconoce algunos de los criterios de la lesión melanocítica para definir la lesión como melanocítica; en segundo lugar, evalúa una serie de criterios específicos de diversas lesiones no melanocíticas de tal manera que la ausencia de criterios específicos de una lesión no melanocítica concreta, debería inducirle a pensar de nuevo en el diagnóstico de lesión melanocítica.

En la segunda etapa, el médico debe ser capaz de reconocer una serie de parámetros asociados al melanoma. Para lo cual se usa un método cualitativo: el análisis de patrones; o métodos semi cuantitativos: regla del ABCD, método de Menzies, Lista de los 7 puntos de Argenziano, etc. Ambos utilizan algoritmos diagnósticos para facilitar el diagnóstico dermatoscópico del melanoma a los dermatólogos menos experimentados en la técnica. Veamos brevemente en que consiste cada método:

1.2.1 MÉTODOS CUALITATIVOS: El Análisis de patrones

En este método es importante seguir las siguientes reglas:

- a) La presencia de un criterio es más importante que su ausencia, puesto que ninguno de estos criterios tiene una especificidad del 100% para el melanoma;
- b) Un solo criterio no es suficiente para hacer el diagnóstico del melanoma;
- c) Algunos criterios son más importantes que otros;
- d) La ausencia de criterios definidos que permitan un diagnóstico por dermatoscopia deben sugerir la posibilidad de que la lesión pueda corresponder a un melanoma.

En este método, los patrones que sugieren melanoma son [4]:

Retículo pigmentado prominente o atípico: El retículo prominente tiene red homogénea con líneas gruesas y oscuras; por otro lado el atípico es heterogéneo e irregular. El retículo pigmentado negativo presenta una estructura de red pigmentada y huecos oscuros que dan la impresión de una imagen “en negativo” del retículo. Esta se presenta en melanoma y nevo de Spitz.

Puntos y glóbulos irregulares: Presenta puntos y globos de varios tamaños y colores espaciados irregularmente en la lesión melanocítica.

Proyecciones irregulares: Cuando hay en la piel que está junto a la lesión estructuras lineales y éstas se distribuyen irregular y asimétricamente; esto sugiere que ha comenzado la fase de extensión superficial del melanoma.

Velo azul-gris o azul-blancuecino: es una coloración difusa azul-grisácea o azul blancuecina, que no tiene estructuras en su interior y no ocupan completamente la lesión.

Se presenta comúnmente como cubierta por un velo blanquecino que la hace verse como vidrio esmerilado. Es una de las características más claras del melanoma.

Áreas desestructuradas: Son áreas dentro de la lesión que se ve claramente ninguna estructura. Presentan o áreas altamente pigmentadas de color marrón, gris o negro; o bien áreas de muy baja coloración y están en forma irregular.

Estructuras de regresión: Presentan porciones regresión azul, blanca y mixta. Éstas se denominan “áreas con punteado azul” o “en pimienta” porque se ven como áreas de color azul-grisáceo con muchos puntos pequeñitos en su interior. Las áreas de regresión blancas parecen una cicatriz superficial. Las áreas de regresión mixtas contienen ambos tipos.

Estructuras vasculares asociadas a la malignidad: Cuando hay melanomas amelánicos estas estructuras pueden ser la única clave diagnóstica. Hay cinco que parecen señalar melanomas:

- Vasos puntiformes o “en cabeza de alfiler” que son vasos que parecen que penetran en el tumor desde la dermis.
- Vasos similares a los anteriores pero son más gruesos verticalmente.
- Vasos lineales que tienen forma y distribución irregular.
- Glóbulos rojo-azulados o rojo-lechosos que corresponden a puntos vascularizados del melanoma.
- Vasos y/o eritema en el interior de estructuras de regresión.

“En el análisis de patrones se evalúa los patrones dermatoscópicos individuales, y también el patrón global de la lesión, que es el patrón predominante. El melanoma puede presentar diferentes patrones globales:

- Patrón reticulado atípico.
- Patrón globular atípico.
- Patrón estallido de estrellas, proyecciones de una distribución radial y regular en toda la periferia de la lesión pigmentada.
- Patrón homogéneo, presente en metástasis de melanoma.
- Patrón paralelo de la cresta, en lesiones palmo-plantares.
- Patrón multicomponente, es la combinación de tres o más, frecuentemente asociado a melanoma.
- Patrón inespecífico, lesiones no clasificables” [4].

1.2.2 MÉTODOS SEMICUANTITATIVOS

Ahora trataremos los métodos o algoritmos semicuantitativos que existen en la literatura. Los más famosos que se conocen son: el método ABCD de Stolz, el método de Menzies, y la lista de los 7 puntos de Argenziano.

ABCD de Stolz [4]

Es un método alternativo al "análisis de patrones" para el diagnóstico dermatoscópico de melanoma. Valora cuatro criterios y es útil para lesiones localizadas en mucosas, o piel lampiña.

- Asimetría. Dividimos lesión en dos ejes perpendiculares y valoramos la simetría del color, de la forma y de las estructuras en cada lado del eje. Si no hay asimetría en ningún eje se asigna una puntuación 0; de 1, si existe asimetría en un eje y de 2 si presenta en ambos ejes. La lesión puede tener una puntuación de 0 a 2.
- Bordes. Dividimos la lesión en ocho (8) regiones y cada región que finalice abruptamente se le asigna un punto (1). La puntuación mínima es de 0 y máxima 8.
- Color. Se le da puntuación a la presencia de seis (6) colores: blanco, marrón claro, marrón oscuro, azul-gris, rojo y negro. La puntuación mínima es de 1 y la máxima de 6.
- Estructuras Dermatoscópicas. Se consideran cinco (5) estructuras cada una de las cuales tiene un punto.
 - ✓ Reticulo pigmentado. Atípico o típico
 - ✓ Áreas desestructuradas. Deben ser más del 10% de la lesión.
 - ✓ Puntos. Deben ser más de dos.
 - ✓ Glóbulos. Deben de ser al menos dos.
 - ✓ Ramificaciones lineales. Deben de ser más de dos.

“Se multiplica cada puntuación por un factor de corrección que depende en cada caso. La puntuación para la asimetría debe multiplicarse por 1.3; la de los bordes por 0.1

y tanto la del color como la de las estructuras dermatoscópicas por 0.5. Al sumar todas las puntuaciones obtiene un valor llamado índice dermatoscópico total (TDS), el cual se tiene que interpretar de la siguiente forma: menor de 4.75 como lesión benigna, de 4.8 a 5.45 se considera sospechosa y se considera su extirpación o su seguimiento estrecho y si es mayor a 5.45 la lesión es altamente sospechosa de melanoma. Posteriormente se añadieron tres criterios adicionales que deben considerados en las lesiones sospechosas: el patrón vascular atípico, áreas de regresión y pseudópodos” [4].

Los 7 puntos de Argenziano:

Algoritmo diagnóstico semicuantitativo creado por Argenziano en 1998 “que tiene en cuenta 7 criterios dermatoscópicos. Dentro de los criterios mayores está el retículo pigmentado atípico, el velo azul-blanquecino y un patrón vascular atípico que recibirán una puntuación de 2 y dentro de los criterios menores están las proyecciones irregulares, los puntos y glóbulos irregulares, las manchas de pigmento irregulares y áreas de regresión que reciben una puntuación de 1. Se realiza la suma de las puntuaciones y si es igual o superior a 3 se diagnosticará la lesión de melanoma con una sensibilidad de 95% y una especificidad de 75%” [4].

Veamos en más detalle los criterios mayores y menores [5]:

Criterios Mayores:

Retículo pigmentado atípico: Retículo marrón, gris o negro con orificios de malla irregulares y mallas gruesas.

Velo azul-blanquecino: Área desestructurada de pigmentación azulada confluyente cubierta por una película blanca “en vidrio esmerilado” que no debe ocupar toda la lesión.

Patrón vascular atípico: Existencia de vasos lineales irregulares o vasos puntiformes en el seno del tumor que no estén asociadas con áreas de regresión.

Criterios Menores:

Proyecciones irregulares: Existencia de proyecciones radiales o pseudópodos de manera irregular en la periferia de la lesión que no estén claramente combinadas con las líneas del retículo.

Puntos y/o glóbulos irregulares: Se consideran como un criterio único en el método de los siete puntos y deben tener distintos tamaños y estar distribuidos de manera irregular en la lesión.

Manchas de pigmento irregulares: Áreas desestructuradas de color marrón, gris o negro distribuidas de forma asimétrica en la lesión.

Estructuras asociadas a regresión: Engloba a las áreas de despigmentación pseudocicatricial y a las áreas azul-grises.

Método de Menzies [4]:

En este método se valoran once criterios dermatoscópicos. Se dividen en criterios negativos, que no deben presentarse en el diagnóstico de melanoma, y criterios positivos que alguno de ellos si debe estar presente para el diagnóstico. Los criterios negativos son simetría y monocromía. Los criterios positivos son el velo azul-blanquecino, la despigmentación pseudocicatrizal, múltiples colores, retículo pigmentado prominente, pseudópodos, proyecciones radiales, múltiples puntos marrones, puntos/glóbulos negros periféricos y múltiples puntos azul-gris. Para llegar al diagnóstico de melanoma la lesión no debe presentar ninguno de los criterios negativos y además debe presentar al menos uno de los nueve criterios positivos.

“En resumen, el primer paso es diferenciar si la lesión pigmentada es o no melanocítica. Si es melanocítica se puede utilizar el ABCD (asimetría, bordes, color y diferentes estructuras) y en caso de presentar dos o más criterios se considera sospechosa de melanoma maligno. Se puede utilizar cualquiera de los algoritmos dermatoscópicos para aumentar la certeza del diagnóstico clínico de melanoma maligno. La dermatoscopia tiene una sensibilidad de 91% y especificidad de 86% y la dermatoscopia digital tiene una sensibilidad de 88% y una especificidad de 79%. En pacientes con alto riesgo para melanoma, se debe considerar el uso de las imágenes de la dermatoscopia digital secuencial para detectar melanoma en lesiones que inicialmente no cumplen con los criterios de malignidad” [4].

Capítulo 2

2.1 Imagen Digital [5]:

Una imagen digital puede ser considerada como una representación discreta de una data, poseyendo ambas la información espacial (layout) y la información de intensidad (color). Una imagen (2D) puede ser definida como una función bidimensional $f(x, y)$, donde “x” e “y” son coordenadas espaciales., y la amplitud de f a cada par de coordenadas (x, y) es llamada intensidad o nivel gris de la imagen de ese punto. El término “nivel de gris” es usado frecuentemente para referirse a la intensidad de las imágenes monocromáticas. Las imágenes de color son formadas por una combinación de imágenes individuales. Por ejemplo, en el sistema de color RGB una imagen de color consiste de tres imágenes monocromáticas individuales, referidas como la imagen (o componentes) roja (R), la verde (G) y la azul (B). Cuando “x”, e “y” además de los valores de amplitud de f son todos finitos, cantidades discretas, llamamos a la imagen una imagen digital. Una imagen digital está compuesta de un número finito de elementos, cada uno de los cuales tiene una locación y valor particular.

La Imagen $I(m, n)$ representa la respuesta de un sensor a una serie de posiciones fijas m y n . Estos datos se derivan de una señal espacial continua $I(x, y)$ a través de un proceso frecuentemente llamado discretización.

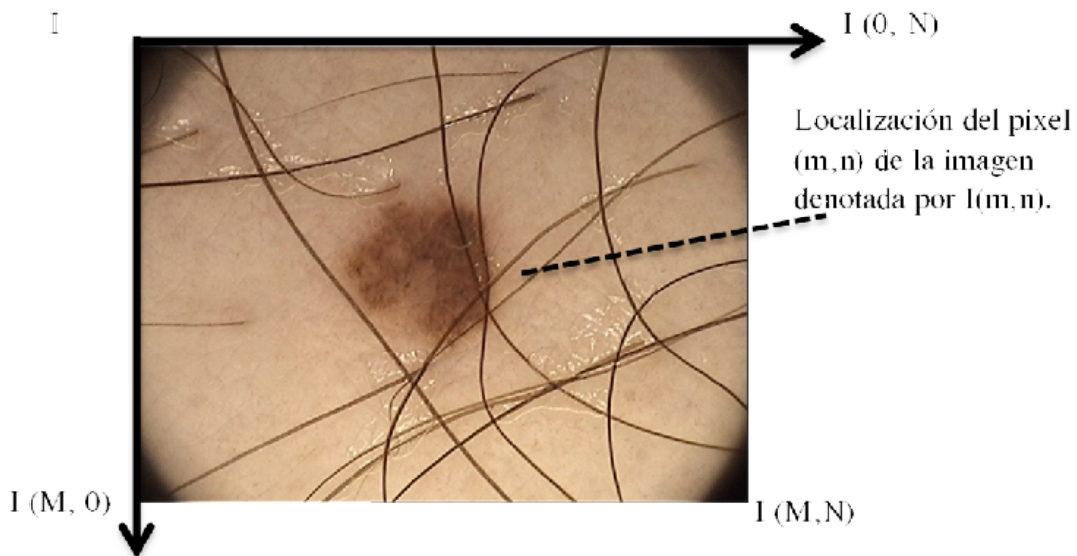


Figura 1: Una representación gráfica de una lesión de piel con sus respectivos píxeles.
(Fuente: Medical Image Analysis Center – MIAC, <https://miac.unibas.ch/miac/>)

La discretización ocurre naturalmente con ciertos tipos de sensores de imagen (tales como cámaras CCD) y básicamente efectúa un promedio local de la señal continua sobre alguna pequeña región (normalmente un cuadrado) en la región de dominio. Los índices m y n designan respectivamente las filas y columnas de la imagen. Los elementos de imagen individuales o píxeles de la imagen están referidos por sus índices (m, n) en 2D. Como trabajaremos con el programa Matlab seguimos su convención, y en esta convención $I(m,n)$ designa la respuesta de un pixel localizado a la m -ésima fila y la n -ésima columna.

2.2 Color de la Imagen Digital:

Una imagen digital contiene una o más canales de colores que definen la intensidad o color a una locación particular de pixel $I(m, n)$. Cada localización del pixel solo contiene un simple valor numérico que representa el nivel de la señal a ese punto de la imagen. La conversión desde este “set” o grupo de números a una imagen mostrada se logra a través del mapa de color. Un mapa de color asigna una específica sombra de color a cada nivel numérico en la imagen para dar una representación visual de la data. En la escala de grises, se asigna a todas las sombras de grises desde el negro (valor cero) a blanco (máximo valor) de acuerdo al nivel de la señal. También se usa en ciertas instancias un falso mapa de color. Esto se hace principalmente porque el sistema visual humano solo es sensitivo a aproximadamente cuarenta (40) sombras de grises en el rango del negro al blanco, mientras que nuestra sensibilidad al color es mucho más fina. Este falso mapa del color puede servir para acentuar o delinear ciertos rasgos o estructuras, haciéndolo fácil de identificar para el observador humano. Esto se usa frecuentemente en imágenes médicas y astronómicas.

Además de estas, tenemos también “imágenes de color verdadero” donde el completo espectro de colores puede ser representado como un vector de tres componentes, típicamente los componentes R, G, B a cada locación en el pixel. Aquí, el color es representado como una combinación lineal de los valores o colores básicos y la imagen puede considerarse como de tres planos 2-D. Otras representaciones de color también son posibles y utilizadas muy ampliamente, tales como (H, S, V) por sus siglas en inglés (Matiz, Saturación y Valor).

2.3 Resolución de la Imagen Digital:

La resolución de una imagen puede especificarse en término de tres cantidades:

- a. *Resolución espacial*: las dimensiones (RxC) filas (Row) por las columnas define el número de píxeles usados para cubrir el espacio visual capturado por la imagen. Comúnmente se escribe: RxC (ejemplo: 640x480m 800x600, 1024x768, etc).
- b. *Resolución temporal*: para un sistema de captura continua como el video, esto es el número de imágenes capturadas en un período de tiempo dado. Comúnmente se refiere a ella como marcos por segundo (fps - frames per second), donde cada imagen individual representa un marco de video (la transmisión común por TV opera a 25 fps si es PAL y a 23,976 fps si es NSTC).
- c. *Resolución en bits*: Esto define el número de valor posible de color/intensidad que un pixel puede tener y relaciona la cuantización de la información de la imagen. Por consiguiente una imagen binaria tiene justo dos colores (blanco o negro), una imagen de escala de grises tiene 256 grados de diferentes niveles, etc.

2.4 Formatos de la Imagen Digital: Existen diferentes tipos de formatos de imagen dependiendo de las características y de su uso.

- GIF: Acrónimo de “Graphics interchange format”. Limitado a solo 256 colores (8 bits), con menor compresión.
- JPEG: Joint Photographic Experts Group, es el de más uso común hoy día. Menor compresión.
- BMP: Bit map picture. Formato básico de imagen, limitado generalmente, no tiene compresión.
- PNG: Portable Network graphics, nuevo formato de menor compresión, diseñado para remplazar al GIF.
- TIF/TIFF: Tagged image (file) format. Altamente flexible, formato adaptable y detallado, existen variantes comprimidas y no comprimidas.

2.5 Tipos de Imagen de Datos

La escogencia del formato de imagen usado puede ser ampliamente determinada no solo por el contenido de la imagen, sino también por el tipo de datos que la imagen requiere para almacenar. Además de la resolución de bit de una imagen dada, un número de distintos tipos de imágenes existen también:

- Imágenes binarias: son arreglos 2D que asignan valor numérico entre 0 y 1 a cada pixel en la imagen. La mayoría de las veces se refieren a imágenes lógicas: el negro corresponde a cero, y el blanco corresponde a uno.
- Imágenes escala de grises: son arreglos 2D que asignan un valor numérico a cada pixel el cual está representado por la intensidad a ese punto.
- RGB o true color: son 3D arreglos que asignan tres valores numéricos a cada pixel, cada valor correspondiente al rojo, verde y azul (RGB).

2.6 Espacios de color.

La representación gráfica que usamos en la paleta de colores, especificando el número y naturaleza de los canales de colores, es generalmente conocido como el espacio de color. En Matlab se trabaja principalmente con dos: RGB y HSV.

RGB: Las imágenes RGB son arreglos que podemos considerar conceptualmente como tres planos “distintos, cada uno que corresponden a los tres canales de color: rojo (R), verde (green - G) y azul (blue-B). Se usa más este espacio de color en representaciones de imágenes digitales porque convenientemente corresponden a los tres colores primarios los cuales son mezclados para mostrar en el monitor o dispositivos similares. En el modelo RGB, cada color aparece en sus componentes primarios del espectro de rojo, verde, y azul. Este modelo se basa en un sistema de coordenadas cartesianas que forma un cubo en el que los valores RGB están en 3 esquinas. Los valores de cian, magenta y amarillo están en las otras 3 esquinas, el negro está en el origen y el blanco está en el vértice más alejado del origen.





Figura 2: El Cubo RGB modelo de representación gráfica del espacio de color RGB. (Fuente: Medical Image Analysis Center – MIAC, <https://miac.unibas.ch/miac/>)

En la figura anterior podemos ver una representación espacial del modelo de color RGB y un diagrama esquemático del cubo RGB a 24 bits. La escala de gris (puntos con valores de RGB iguales) se extiende del negro al blanco en la línea que une los puntos negro y blanco. Los diferentes colores del modelo son puntos sobre o dentro del cubo, y se definen por medio de vectores que se extienden desde el origen. Las imágenes representadas en el modelo RGB consisten en 3 imágenes componentes, cada una de un color primario. El número de bits utilizado para representar cada pixel en el espacio RGB se llama profundidad de pixel. Considérese una imagen en la que cada una de las imágenes roja, azul y verde es una imagen de 8 bits. En estas condiciones se dice que cada pixel de color RGB (una tupla (R, G, B)) tiene una profundidad de 24 bits. El número total de colores en una imagen RGB de 24 bits es de $(2^8)^3 = 16,777,216$. En la figura siguiente veremos una imagen de una lesión de piel y ofrecemos la separación en los tres canales de RGB.



**Figura 3: Lesión de piel separa en los tres canales de color RGB respectivamente.
(Fuente: Dra. De Santis. UCV, Caracas, Venezuela)**

- Esta separación de canales se hizo en Matlab usando el siguiente código:

```
D=imread('foto 7.jpg');
Dred= D(:,:,1);
Dgreen= D(:,:,2);
Dblue= D(:,:,3);
subplot(2,2,1); imshow (D); axis image
subplot(2,2,2); imshow (Dred); title('red');
subplot(2,2,3); imshow (Dgreen); title('green');
subplot(2,2,4); imshow (Dblue); title('blue');
```

El sistema RGB es atractivo en si por la representación fiel de la tricromaticidad, además de ser fuente elemental en la adquisición y visualización de las imágenes. El procesamiento individual de estos planos permite extraer formas y detalles significativos de las imágenes.

Entre las desventajas del modelo RGB destacan:

- No uniformidad.
- No es posible evaluar la diferencia observada entre colores con una medida de distancia a partir de los primarios R, G y B. No es un modelo intuitivo psicológicamente.
- Es difícil describir un color con cantidades y porcentajes de los primarios del espacio.

Conversión de RGB a una imagen de escala de grises.

Hacemos esta conversión de un espacio de color RGB a una imagen de escala de grises usando una simple transformación. Esta conversión simplifica o reduce la cantidad de información en la imagen. Por consiguiente una imagen de escala de grises contiene menos información que una imagen a color. La mayoría de la importancia, características que dan información son mantenidas, tales como bordes, regiones, manchas, uniones y así sucesivamente. Veamos la transformación: $I_{\text{grey-scale}}(n,m) = \alpha I_{\text{color}}(n,m,r) + \beta I_{\text{color}}(n,m,g) + \gamma I_{\text{color}}(n,m,b)$. La imagen en escala de grises es esencialmente una suma ponderada de los canales de color rojo, verde y azul. Los coeficientes de ponderación (α , β , γ) son proporcionales a la respuesta perceptual del ojo humano a cada canal de color. Veamos la misma foto pero ahora convertida en escala de grises:




Figura 4: Lesión de piel presentada en RGB y luego convertida a escala de grises respectivamente.

(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

Esta separación de canales se hizo en Matlab usando el siguiente código:

```
>> E=imread ('foto 7.jpg');
>> Egray=rgb2gray (E);
>> subplot (2,1,1); imshow (E); axis image; title ('RGB');
>> subplot (2,1,2); imshow (Egray);title ('grey-scale');
```

Explicación de HSV: el espacio de color perceptual es una manera alternativa de representar las imágenes de color verdadero de forma más natural a la percepción humana y al entendimiento del color que la representación RGB. La representación de color Hue, Saturation y Value (HSV) sigue un gradiente de color perceptualmente aceptable. Desde una perspectiva de análisis de imagen, nos permite la separación de color desde la iluminación menor a un mayor grado. El ser humano no reconoce un color por tener una cantidad de componente roja, verde o azul, sino que emplea atributos perceptuales de luminancia o intensidad, saturación y matiz. Los modelos cromáticos HSI, HLS, HSV y sus variantes, en adelante HSI, codifican el color con los atributos anteriores y se definen como espacios intuitivos, psicológicos u orientados al usuario, pues son los óptimos para interacción humana. Podemos llegar al modelo HSI a partir del modelo RGB con una transformación de coordenadas. Con la transformación, el cubo RGB pasa a tener forma cilíndrica. Los modelos HSI poseen aspecto cilíndrico, de forma que la saturación se corresponde con un valor de distancia radial, mientras que el matiz es función de ángulo en el sistema de coordenadas polar. La intensidad es la distancia a lo largo del eje perpendicular al plano de coordenadas polares:




Figura 5: Representación Gráfica del espacio de color HSV.

(Fuente: Solomon & Breckon, Fundamentals of Digital Image, págs.13)

El modelo general HSI no es el único de la familia intuitiva. Existen espacios de color específicos aplicados en visión por computador. Dos de estos modelos reciben el nombre de HSV y HLS. La figura a continuación ofrece la interpretación geométrica de estos espacios. Se diferencian entre sí y del modelo general HSI por los valores de saturación y de la componente acromática que, en el caso del espacio HSV recibe el nombre de valor, mientras que en el caso de HLS se habla de luminancia. En particular, el modelo HSV, propuesto por [Smith, 1978] posee forma de cono en el que los colores altamente saturados como el rojo, verde o azul puro comparten valor con el blanco. Veamos cómo son gráficamente los canales de hsv.




Figura 6: Lesión de piel presentada en RGB y luego separa en los tres canales de HSV respectivamente.

(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

- Esta separación de canales fue hecha en Matlab siguiendo los siguientes comandos:

```
F = imresize (E, [135 198]);
D=F;
Dhsv=rgb2hsv(D);
subplot(2,2,1); imshow (D); axis image; title ('RGB');
Dh=Dhsv(:, :, 1); subplot(2,2,2); imshow (Dh); title ('Hue');
Ds=Dhsv(:, :, 2); subplot(2,2,3); imshow (Ds); title ('Saturation');
Dv=Dhsv(:, :, 3); subplot(2,2,4); imshow (Dv); title ('Value');
```

- H (hue) es la longitud de onda del color dominante, ejemplo: rojo, azul o verde.
- S (saturation) es la ‘pureza’ del color (en el sentido de la cantidad de luz blanca mezclada con ello).
- V (value) es el brillo del color (también conocido como luminancia).

2.7 Formación de la Imagen.

- Cómo se forma la imagen: el proceso de formación de la imagen puede resumirse como un pequeño número de elementos claves:
- Imagen= PSF*función objeto + ruido. Y también $S=p*o + n$.
- **PSF**: Point Spread Function. Esta describe la manera en que se extiende la información sobre la función objeto que resulta registrado en la data.
- **Función Objeto**: este describe al objeto o escena que está siendo registrada (su superficie o estructura interna, por ejemplo) y la manera en que la luz es reflejada desde la estructura hasta el instrumento que registra la imagen.
- **Ruido**: esta es una función no determinística la cual, puede, en el mejor de los casos, solo ser descrita en términos de alguna distribución estadística (ejemplo, Gaussiana). El ruido es una función estocástica la cual es consecuencia de todas las perturbaciones externas no buscadas que ocurren durante el registro de la data de la imagen.
- (*) **Operador Convolución**: Una operación matemática la cual convuelve una función con otra. **Veamos**:

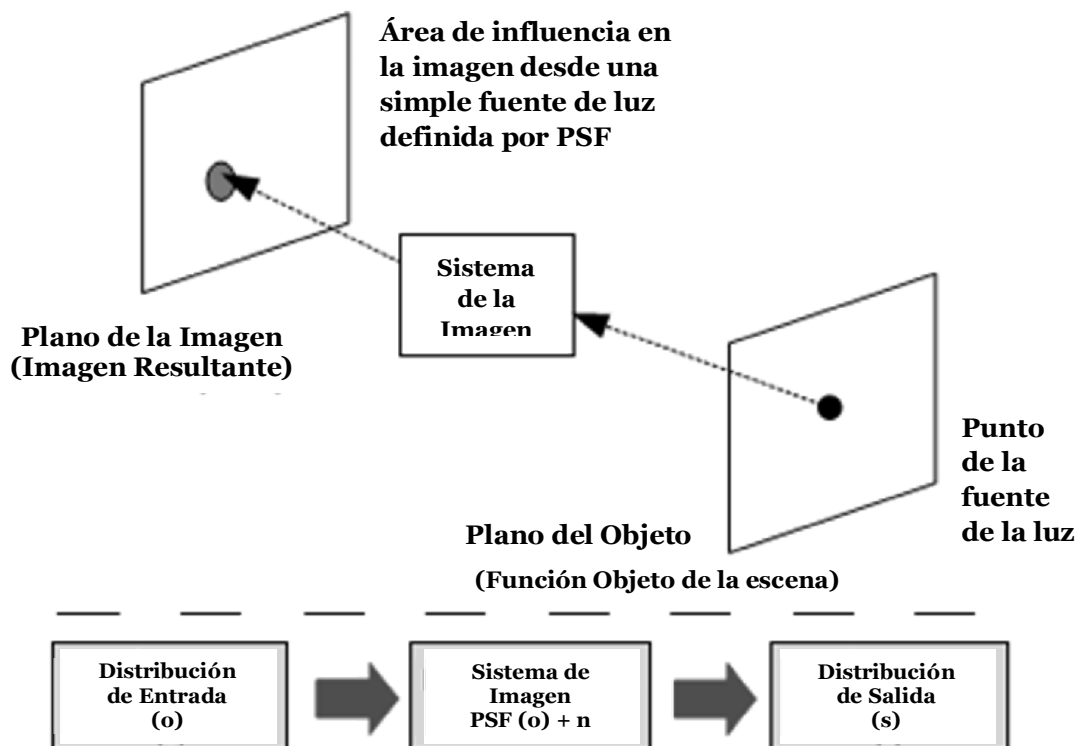


Figura 7: Una visión general del sistema de formación de imagen y el efecto del PSF.

(Fuente: Solomon & Breckon, *Fundamentals of Digital Image*, págs.22)

Explicamos el gráfico: aquí vemos la función de luz reflejada desde el objeto o escena (función objeto) es transformada en una representación de la data de la imagen por la Convolución con el PSF. Esta función caracteriza el proceso de formación o captura de la imagen. El proceso es afectado por el ruido.

La Matemática de la formación de la imagen: el proceso de formación de una imagen puede ser expresada matemáticamente. Podemos verlo como un proceso en el cual se transforma una distribución de entrada en una distribución de salida. El proceso por el cual un sistema de imagen transforma la entrada en una salida puede ser visto de una perspectiva alternativa, llamada de Fourier o dominio de frecuencia. Desde esta perspectiva, la imagen consiste de una superposición de funciones armónicas de diferentes frecuencias.

Convolución, importancia y significado: Una gran cantidad de procesos de formación de imagen son bien descritos por el proceso de Convulación. El teorema de convolución nos capacita para entender y visualizar el proceso de Convulación en el dominio de frecuencia espacial. Una integral de convolución es un tipo de integral de superposición. Todas las coordenadas por la cual el área de superposición no es cero define el rango de la convolución. Un detector que puede captar una señal pequeña tipo delta recibe un señal de intensidad desde la fuente a través de un agujero de tamaño de alfiler. La imagen resultante es una convolución de la fuente con este agujero PSF. En el procesamiento digital de imágenes, las señales son discretas y no continuas. Bajo tales condiciones, la convolución de dos funciones es calculada por la discretización de la integral de convolución.

$$g(x) = f(x) * h_1(x) * h_2(x) \dots * h_n(x).$$




Figura 8: Una explicación gráfica de la convolución.

(Fuente: Solomon & Breckon, *Fundamentals of Digital Image*, págs.32)

Pixel: Un pixel es una abreviación de “picture element”. Indexado como (x,y) o la locación columna-fila a partir del origen de la imagen. Este representa, el más pequeño elemento constitutivo en una imagen digital y contiene el valor numérico el cual es la unidad base de la información interna de la imagen a una resolución espacial y nivel de cuantización dado.




Figura 9: Una imagen ampliada donde se logran ver los píxeles.

(Fuente: <http://es.wikipedia.org/wiki/Pixel>)

Operación sobre píxeles e imágenes: las operaciones que se pueden realizar son de tipo aritmética o lógicas.

Operaciones aritméticas: Operaciones básicas aritméticas pueden ser logradas rápida y fácilmente para lograr una variedad de efectos y aplicaciones. Añadiendo un valor a cada píxel de la imagen podremos lograr los siguientes efectos:

Ajuste de Contraste: Añadiendo un valor positivo constante C a cada píxel se incrementa su valor y, por tanto, su brillo.

```
E=imread('yo.JPG');
subplot(1,2,1), imshow(E); title('Imagen');
F=imadd(E,100); subplot(1,2,2), imshow(F); title('Imagen + 100');
```



Figura 10: Lesión de piel en original comparada con la misma imagen sumada a un valor de 100.

(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

Mezclado: Añadiendo imágenes juntas produce una composición de imágenes de ambas imágenes de entrada. Aplicamos la siguiente instrucción:

```
C=imread('foto 3.jpg');subplot (1,3,1), imshow(C), title ('Foto 3');
D=imread('foto 6.jpg');subplot (1,3,2), imshow(D), title ('Foto 6');
G=C+D; subplot (1,3,3), imshow(G), title ('Foto 3 + Foto 6');
```




Figura 11: Dos lesiones de piel sumadas.
(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

Multiplicación y división de imágenes: pueden ser usadas para el ajuste de contraste y una extensión de la operación de adición/sustracción. Este procedimiento es algunas veces referido al escalamiento del color de la imagen.

```
A= imread ('foto 3.jpg'), subplot(1,3,1), imshow(A);title ('image');
B=immultiply(A,1.5); subplot(1,3,2), imshow(B); title ('image X 1.5');
C=imdivide(A,4); subplot(1,3,3), imshow(C); title ('image /4');
```



Figura 12: La lesión de piel “foto 3” multiplicada por 1,5 y dividida entre 4 respectivamente.
(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

Operaciones lógicas sobre la imagen: podemos aplicar a las imágenes las siguientes operaciones lógicas: NOT, OR, XOR y AND.

- **NOT:** este operador invierte la representación de la imagen. En el simple caso de una imagen binaria, los pixeles negros se vuelven blancos y viceversa.
- **OR/XOR:** es muy útil para procesar imágenes de valores binarios (0 o 1) para detectar objetos los cuales se mueven entre este rango de valores. Los objetos binarios son producidos típicamente a través de la aplicación de la umbralización de imagen de escala de grises.

- **AND**: este operador lógico es comúnmente usado para detectar diferencias en imágenes, destacando regiones con una máscara binaria o produciendo planos a través de una imagen. Veamos los ejemplos en imágenes:

```
A= imread ('foto 3.jpg'), subplot(1,3,1); imshow(A); title ('image');
Abw=im2bw(A); subplot(1,3,2), imshow(Abw);title('image bw');
D=not(Abw); subplot (1,3,3), imshow (D); title ('NOT image bw');
```



Figura 13: La lesión de piel “foto 3”, luego convertida en blanco y negro (image bw) y luego negada usando el operador NOT respectivamente.

(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

```
A= imread('foto 3.jpg'); subplot(3,3,1); imshow(A); title ('Foto 3');
Abw=im2bw(A); subplot(3,3,2), imshow(Abw); title (' Foto 3 bw');
B=imread('foto 6.jpg'); subplot(3,3,3), imshow(B); title ('Foto 6');
Bbw=im2bw(B); subplot(3,3,4), imshow(Bbw); title (' Foto 6 bw');
C=or(Abw,Bbw); subplot(3,3,5), imshow(C); title('nos OR');
D=xor(Abw,Bbw); subplot(3,3,6), imshow(D); title('nos XOR');
E=and(Abw,Bbw); subplot(3,3,7), imshow(E); title('nos AND');
```




Figura 14: La lesión de piel “foto 3” y “foto 6”, luego de convertida en blanco y negro son sumadas y se le aplican los operadores OR, XOR y AND respectivamente.

(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

Distribución de píxeles: histogramas.: Un histograma de una imagen es un gráfico de la frecuencia relativa de la ocurrencia de cada valor de píxel permitido en la imagen contrastado con los valores en sí mismo. Un histograma de color es una representación anterior de la distribución del color en una imagen. En las imágenes digitales un histograma de color representa el número de píxeles que tienen colores en cada una de las listas fijas de rangos de colores, que se extienden sobre el espacio de color de la imagen, es decir el conjunto de todos los posibles colores. El histograma de color puede ser construido para cualquier tipo de espacio de color, aun cuando el término es usado más frecuentemente en espacios tridimensionales como RGB o HSV. Si normalizamos el gráfico de la frecuencia de modo que la suma de todas las frecuencias sobre el rango permisible al valor de uno (1), podemos tratar el histograma de la imagen como una función densidad de probabilidad discreta la cual define la probabilidad de que un valor de píxel dado ocurra en la imagen. Para una simple imagen en escala de grises, el histograma puede construirse por un simple conteo de los números de veces que cada valor de la escala de grises (0-255) ocurre en la imagen. Una inspección visual de una imagen puede revelar el contraste básico que está presente en una imagen y cualquier diferencia potencial en la distribución de color de los componentes de la escena de la imagen.

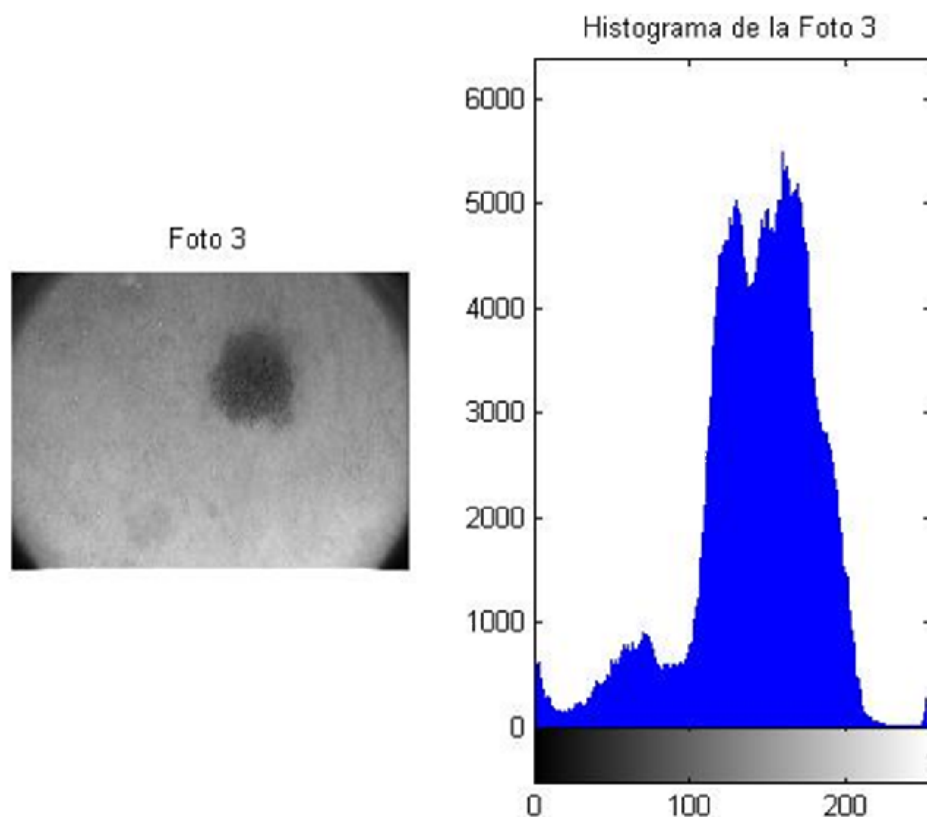


Figura 15: La lesión de piel “foto 3” y su respectivo histograma
(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

2.8 Realce de Imágenes: Esta técnica considera la manipulación del rango dinámico de una imagen digital dada para mejorar la visualización de su contenido. La meta básica del realce de una imagen es procesar la imagen tal que podamos ver y evaluar la información visual que contiene con gran claridad.

- El realce de una imagen tiene por objetivo su procesamiento para obtener una nueva imagen con mejor apariencia, o para generar otra que sea más fácil de analizar por un especialista o una máquina.
- La remoción del ruido, el afilado de los bordes de las imágenes, el enfoque suave o difuminado son ejemplos de cómo los fotógrafos usan técnicas populares de realce. Estas y otras técnicas de realce pueden ser logradas a través del proceso de filtrado de dominio espacial.
- El realce en el dominio espacial opera directamente en el plano de la imagen y se fundamenta en la manipulación directa de los píxeles.
- El realce en el dominio de las frecuencias opera en el plano de la transformada de Fourier de la imagen.
- Los filtros actúan sobre una imagen para cambiar los valores de los píxeles de alguna manera específica, y éstas se clasifican en dos maneras: lineales y no lineales.
- Independientemente del filtro que sea usado, todas las aproximaciones de filtrado de dominio espacial operan en la misma manera simple. Cada pixel en una imagen-el pixel bajo consideración a un momento dado llamado target pixel o pixel objetivo- es continuamente manejado. El valor del pixel objetivo es reemplazado por un nuevo valor el cual depende solo del valor de los píxeles en una específica vecindad alrededor del pixel objetivo.

• **Vecindad de píxeles.**

- Una importante medida en las imágenes es el concepto de conectividad. La mayoría de las operaciones en el proceso de imágenes usan el concepto de vecindad




Figura 16: Vecindades de un pixel de 4 y 8 píxeles
(Fuente: PPT Dr. Wuilliam Torres, UCV, Caracas Venezuela)

local de la imagen que se define como un área local de influencia, relevancia o interés.

- Otro concepto a manejar es la conectividad, lo cual es simplemente analizar cuáles son los pixeles que están conectados. Cuando hablamos de 4-conectividad, solo los pixeles N, W, E, S de un pixel dado están conectados. Cuando hablamos de 8-conectividad, entonces los pixeles N, NW, W, NE, E, SE, SW, S están conectados.
- El nuevo o el valor filtrado del pixel objetivo es determinado como una combinación lineal de los valores de los pixeles de la vecindad. Otro tipo de filtro, es por definición, un filtro no-lineal.
- La combinación lineal específica de la vecindad de un pixel es aquella que es tomada y determinada por el filtro kernel (frecuentemente llamada máscara).
- Muchos filtros kernel son algunas veces descritos como kernels de convolución.
- Los pasos en un filtrado lineal (convolución) pueden ser resumidos como sigue:
 - Define el filtro kernel.
 - Desliza el kernel sobre la imagen tal que el pixel central coincida con cada pixel en la imagen.
 - Multiplica los pixeles que están debajo del kernel por el correspondiente valor (peso) en el kernel bajo ella y suma el total.
 - Copia el valor resultante en la misma locación en la nueva imagen filtrada.
- **Filtros para remover ruido.**
- Uno de los primeros usos de ambos filtros: lineales y no lineales, es la remoción del ruido. Veremos e investigaremos la aplicación de un número de filtros diferentes para remover típicos ruidos. Veremos el filtrado medio, el filtrado de mediana, el filtrado de rango, y el filtro gaussiano.
- Para mostrar las ventajas de estos procesos de filtrado vamos a crear dos imágenes con ruido, una con ruido conocido como “salt and pepper” y otro el ruido “gaussiano”.

```
I=imread('foto 3.jpg');
A=rgb2gray(I); subplot(1,3,1), imshow(A), title ('Foto 3
original');
Isp=imnoise(A,'salt & pepper', 0.03);
subplot(1,3,2), imshow(Isp), title(' Foto 3 with salt and pepper');
Ig=imnoise(A,'gaussian', 0.02);
subplot(1,3,3), imshow(Ig), title (' Foto 3 gaussian');
```




Figura 17: Foto 3 original con ruido “salt and pepper” y con ruido “gaussiano” respectivamente
(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

El filtrado medio: es tal vez el más simple filtro lineal y opera al dar igual peso w_k a todos los pixeles en la vecindad. Un peso de $w_k=1/(NM)$ es usado para una vecindad de $N \times M$ pixeles y tiene el efecto de suavizar la imagen, reemplazando cada pixel en la imagen de salida con el valor medio de la vecindad $N \times M$. En Matlab el filtro medio se aplica con el siguiente comando:

```
I=imread('foto 3.jpg');
A=rgb2gray(I);
Isp=imnoise(A,'salt & pepper', 0.03);
Igm=imnoise(A,'gaussian', 0.02);

k=ones(3,3)/9;
Im=imfilter(A,k);
Ispm=imfilter(Isp,k);
Igm=imfilter(Igm,k);
subplot(1,3,1), imshow(Im), title('Foto 3 original filtrada');
subplot(1,3,2), imshow(Ispm), title('Foto 3 salt and pepper filtrado');
subplot(1,3,3), imshow(Igm), title('Foto 3 gaussiana filtrado');
```




Figura 18: Foto 3 original filtrada, luego con ruido “salt and pepper” filtrado y con ruido “gaussiano” filtrado respectivamente
(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

Filtro de Mediana: Otro filtro comúnmente utilizado es el filtro de mediana. Este vence las limitaciones del filtro medio, pero a una costosa inversión computacional. A todo pixel que se dirige, es reemplazado por la mediana estadística de los $N \times M$ pixeles de la vecindad en lugar de la media. El filtro de mediana es superior al filtro de media en el sentido en que es mejor en la preservación de los picos de alta frecuencia (i.e bordes), también eliminando ruidos de puntos aislados tales como “salt and pepper”. He aquí el comando:

```
I=imread('foto 3.jpg');
A=rgb2gray(I);
Isp=imnoise(A,'salt & pepper', 0.03);
Igm=imnoise(A,'gaussian', 0.02);

subplot(2,3,1), imshow(A), title ('Foto 3 original');
subplot(2,3,2), imshow(Isp), title('with salt and pepper');
subplot(2,3,3), imshow(Igm), title ('gaussian');
Im=medfilt2(A, [3 3]); subplot (2,3,4), imshow(Im); title
('filtro mediana');
Ispm= medfilt2(Isp, [3 3]); subplot (2,3,5), imshow(Ispm),
title ('SP filtro mediana');
Igm= medfilt2(Igm, [3 3]); subplot (2,3,6), imshow(Igm), title
('gaussiana filtro mediana');
```




Figura 19: Foto 3 original con ruido “salt and pepper” y con ruido “gaussiano” y luego filtradas con mediana, con SP mediana y gaussiana filtro mediana respectivamente
(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

Filtro de Rango: el filtro de mediana es realmente un caso especial de un filtro de orden generalizado o de rango. El filtro de orden general es un filtro no lineal que cumple con los siguientes pasos comunes:

- Define la vecindad del pixel objetivo (NxN).
- Ranquea los pixeles en orden ascendente (de menor a mayor valor).
- Escoge el orden del filtro (desde 1 hasta N).
- Organiza el valor del filtro para ser igual al valor del pixel de rango.

```
I=imread('foto 3.jpg');
A=rgb2gray(I);
Isp=imnoise(A,'salt & pepper', 0.03);
Ig=imnoise(A,'gaussian', 0.02);
Im=ordfilt2(A, 25, ones(5,5)); subplot(1,3,1), imshow(Im), title
('original con filtro de rango'); %
Ispm=ordfilt2(Isp, 25, ones(5,5)), subplot(1,3,2), imshow(Ispm),
title ('S&P con filtro de rango');
Igm=ordfilt2(Ig, 25, ones(5,5)), subplot(1,3,3), imshow(Igm), title
('Gaussiana con filtro de rango');
```




Figura 20: Foto 3 original con “filtro de rango”, luego con “salt and pepper” con filtro de rango y con ruido “gaussiano” con filtro de rango respectivamente
(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

Filtro Gaussiano: este filtro es muy importante. Aquí filtramos la imagen usando un kernel discreto derivado de una simetría radial de una función continua Gaussiana 2D definida como:

$$\bullet f(x, y) = \left[\frac{1}{(2\pi\sigma^2)} \right] e^{-(x^2+y^2)/2\sigma^2}$$

- Las aproximaciones discretas a esta función continua son especificadas usando dos parámetros libres:
- El tamaño designado del kernel (como un filtro NxN de máscara).
- El valor de σ , la desviación estándar de la función Gaussiana.

- Como es siempre el caso con los filtros de convolución lineal, aquí hay una compensación entre la precisión del muestreo de la función y el tiempo computacional requerido para implementarlo.
- Aplicar el filtro Gaussiano tiene el efecto de suavizar la imagen, pero es usado en una forma que es algo diferente al filtro medio. Primero el grado del suavizado es controlado por la escogencia del parámetro de desviación estándar σ , no por el valor absoluto del tamaño del kernel (lo que si pasa en el caso del filtro medio). Segundo la función gaussiana tiene una propiedad muy especial frente a la transformada de Fourier que ella es también una función gaussiana, lo que la hace muy conveniente para el análisis de filtros de dominio de frecuencia.
- Una función gaussiana con un alto valor de σ es un ejemplo de lo que se le llama filtro pasa-bajos en el cual el contenido de alta frecuencia espacial (i.e. rasgos de bordes afilados) de una imagen son suprimidos.
- Apliquemos el filtro gaussiano en Matlab:
- Comando para las imágenes a las que se le aplica el ruido y luego el filtro gaussiano:

```

close all
clear all
clc
I=imread('foto 3.jpg');
A=rgb2gray(I); subplot(2,3,1), imshow(A), title ('Foto 3
original');
Isp=imnoise(A,'salt & pepper', 0.03);
subplot(2,3,2), imshow(Isp), title('Foto 3 with salt and pepper');
Ig=imnoise(A,'gaussian', 0.02);
subplot(2,3,3), imshow(Ig), title ('Foto 3 gaussian');

k=fspecial('gaussian', [5 5], 2);
Igf=imfilter(A,k), subplot(2,3,4), imshow(Igf),title('original
filtrado gaussiano');
Ispg=imfilter(Isp,k), subplot(2,3,5), imshow(Ispg),title('S&P
filtrado gaussiano');
Igg=imfilter(Ig,k), subplot(2,3,6), imshow(Igg),title('Gaussiano
con filtrado gaussiano');

```




Figura 21: Foto 3 original con “filtro gaussiano” en sus tres versiones respectivamente
(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

- Aquí definimos un filtro gaussiano con kernel 5×5 y $\sigma = 2$ usando la función Matlab `fspecial` y aplicándola a tres imágenes generadas.
- Suavizado gaussiano (o filtrado) forma comúnmente la primera etapa de un algoritmo de detección de borde.

Filtros para detección de bordes.

- Además de la remoción de ruido, los otros dos usos principales del filtrado de imagen son para:
 - Extracción de características.
 - Realzado de las características.
- Un borde puede ser considerado como una discontinuidad o gradiente dentro de la imagen. Como resultado, la consideración de filtros de derivadas es central para la detección de bordes en procesamiento de imágenes.

Filtros derivativos para discontinuidades:

- Los filtros derivativos pueden ser usados para la detección de discontinuidades en una imagen y juega un rol central en el realce de los finos detalles de una imagen (sharpening).
- Detección de bordes es básicamente un método de segmentación de una imagen en regiones basadas en discontinuidades, esto nos permite observar aquellas características de una imagen donde es más o menos abrupto el cambio en niveles de grises o texturas, indicando el fin de una región en una imagen y el principio de otra. Realzando o amplificando la presencia de estas discontinuidades en la imagen nos permite mejorar la calidad de la imagen percibida bajo ciertas condiciones. Sin embargo, como otros métodos de análisis de imágenes, la detección de bordes es sensible al ruido.
- La detección de bordes está dividida en dos principales categorías: primer orden de detección de bordes y segundo orden de detección. El primer orden de detección está basado en el uso de las derivadas de primer orden. Y el segundo orden de detección de bordes está basado en las derivadas de segundo orden.

Primer orden de detección de bordes:

- Un número de filtros kernel han sido propuestos los cuales aproximan la primera derivada del gradiente de una imagen. Tres de los más comunes son: Roberts, Prewitt y Sobel filtros kernel de detección de bordes. Todos los tres son implementados como una combinación de dos kernels; uno para la derivada en “x” y otro para la derivada en “y”.
- El simple 2x2 **operador Roberts** fue uno de los primeros métodos empleados para detectar bordes. Calcula una simple, pero eficiente, medida del gradiente espacial 2D sobre la región de importancia de una imagen que corresponde a un borde. El operador Roberts es implementado usando dos mascararas de convolución cada una designada para responder máximamente a los bordes corriendo a 45° la rejilla de pixeles los cuales retornan la imagen derivada de x y derivada de y, G_x y G_y respectivamente.
- El kernel Prewitt/Sobel es generalmente preferido al de Roberts a causa que el gradiente no es desplazado a la mitad por un pixel en ambas direcciones y la extensión para tamaños grandes no es realmente posible con el operador Roberts.

- La diferencia clave entre el operador Sobel y el Prewitt es que el kernel del Sobel implementa diferenciación en una dirección y promedio gaussiano aproximado en la otra. Veamos:

```
A=imread('8bn.png');
I=A; subplot (2,2,1), imshow(I), title ('lesion 8 original');
IEr=edge(I,'roberts'); subplot (2,2,2), imshow(IEr), title
('lesión 8 bajo Roberts Edges');
IEp=edge(I,'prewitt'); subplot (2,2,3), imshow(IEp), title
('lesion 8 bajo Prewitt Edges');
IEs=edge(I,'sobel'); subplot (2,2,4), imshow(IEs), title
('lesion 8 bajo Sobel Edges');
```

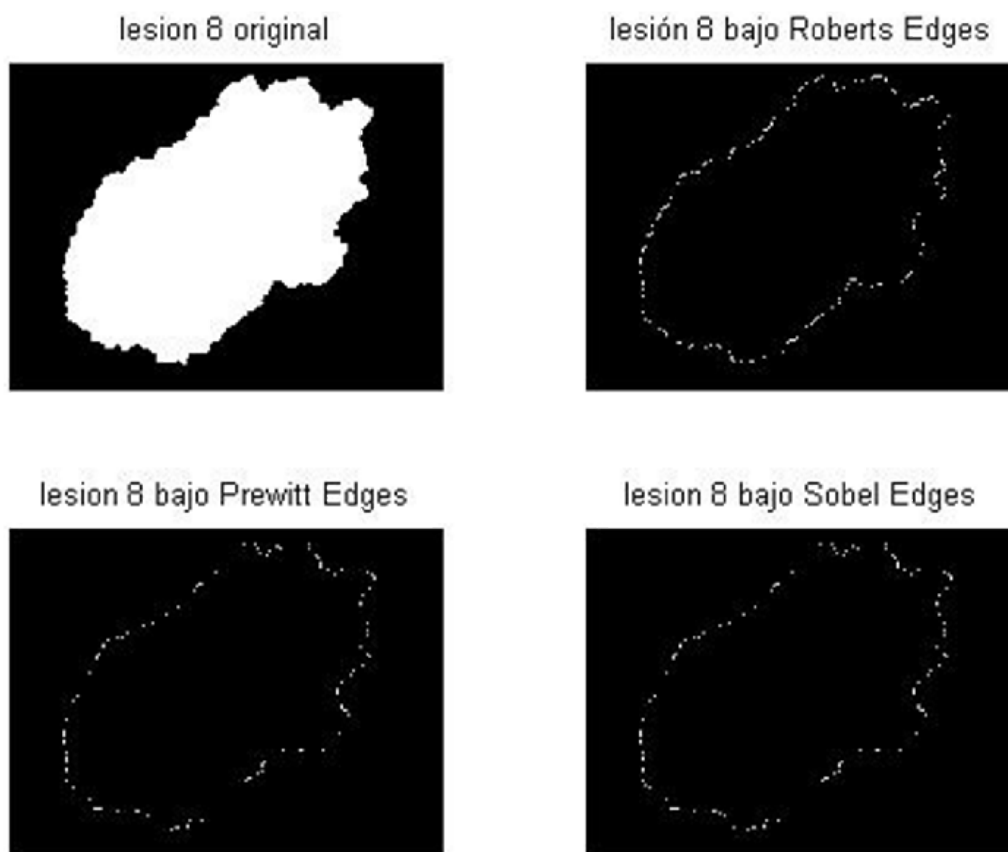


Figura 22: Foto 8 (lesión 8) original segmentada, luego bajo el operador Roberts Edges, luego Prewitt Edges y finalmente bajo Sobel Edges respectivamente
(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

Segundo Orden de Detección de Bordes.

- El operador más comúnmente usado para realzar los bordes de una imagen en el segundo orden de detección es el operador Laplaciano.

$$\bullet \nabla^2 f(x, y) = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}$$

- Esto puede ser fácilmente implementado en un filtro kernel 3x3. Sin embargo, si exploramos una imagen aplicando este operador localmente, entonces la expectativa es una respuesta que será alta en aquellos puntos en la imagen donde el gradiente local cambia más rápidamente.

Laplaciano del Gaussiano:

- Para lograr una alta sensibilidad del filtro Laplaciano, el kernel Laplaciano estándar es comúnmente combinado con el kernel Gaussiano para producir un método de filtrado robusto. Estos dos kernels pueden ser aplicados secuencialmente a la imagen como dos operaciones separadas de convolución, primero se suaviza con el kernel Gaussiano y luego con Laplaciano.
- Sin embargo, como la convolución es asociativa, podemos combinar los kernels por la convolución del suavizado del operador gaussiano con el operador Laplaciano produciendo un simple kernel: el Filtro Laplaciano del Gaussiano (LoG). Este simple kernel es entonces aplicado a la imagen en un simple paso.

```
I=rgb2gray(imread('foto 3.jpg'));
k=fspecial('log', [10 10], 3.0);
IEzc=edge(I, 'zerocross', [], k);
subplot(1,2,1), imshow(I), title('Foto 3 escala de grises');
subplot(1,2,2), imshow(IEzc), title('Foto 3 con LoG Filter');
```

Foto 3 escala de grises




Foto 3 con LoG Filter




Figura 23: Foto 3 en escala de grises y luego con LoG Filter respectivamente
(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

2.9 Realce de Bordes: en esta parte veremos el uso del segundo orden de detección de bordes como un método para realzar el borde comúnmente conocido como nitidez de la imagen.

- **Perfilado Laplaciano de bordes:** hemos visto que el Laplaciano responde solo a los finos detalles en la imagen (es decir, aquellas regiones de la imagen donde el cambio del gradiente es significativo) pero tiene una respuesta nula a las regiones contantes y las regiones de suave gradiente en la imagen.
- Si por el contrario, tomamos la imagen original y sumamos o sustraemos el Laplaciano, entonces podemos esperar realzar los finos detalles en la imagen artificialmente.
- $I_{\text{output}}(x,y) = I_{\text{in}}(x,y) - \nabla^2 I_{\text{in}}(x,y)$.

```
I=rgb2gray(imread('foto 3.jpg'));
subplot(1,3,1), imshow(I); title('Foto 3 escala de grises');
h=fspecial('laplacian');
B=imfilter(I,h), subplot(1,3,2), imagesc(B); axis image; axis
off, title('Foto 3 bordes');
C=imsubtract(I,B), subplot(1,3,3), imshow(C); title('Foto 3
con perfilado');
```

Foto 3 escala de grises




Foto 3 bordes



Foto 3 con perfilado




Figura 24: Foto 3 en escala de grises y luego con el perfilado y el laplaciano de bordes respectivamente
(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

2.10 Procesos Morfológicos: la palabra morfología significa el estudio de la forma o la estructura. En procesamiento de imágenes usamos la morfología matemática como un medio para identificar y extraer significativos descriptores de la imagen basados en propiedades de la forma o de las figuras inherentes en la imagen.

- **Imágenes binarias:** una imagen binaria es una imagen la cual cada pixel asume uno de solo dos posibles valores discretos y lógicos: 1 ó 0. El valor lógico 1 es descrito como “alto”, “verdadero” o “en”, mientras que el valor lógico “0” se describe como “bajo” “falso” o “fuera”. En procesamiento de imágenes, nos referimos a los pixeles en una imagen binaria dándole el valor “1” a los pixeles del primer plano y valor “0” a los pixeles del segundo plano.
- Un objeto en una imagen binaria consiste de un grupo de pixeles conectados.
- Dos definiciones de conexión entre pixeles son comúnmente usados. Si requerimos que un pixel del primer plano deba tener al menos un pixel vecino del primer plano del norte, este, oeste y sur para ser considerado como parte del mismo objeto, entonces estamos usando 4-conexión.
- Si por el contrario, para que un pixel sea considerado de la vecindad del primer plano debe estar en cualquiera de los siguientes puntos: noreste, noroeste, sureste, suroeste, norte, sur, este y oeste; entonces estamos usando 8-conexión.
- Desde la perspectiva de las imágenes binarias las únicas propiedades de interés son la forma, el tamaño y la locación del objeto en la imagen. Por tanto, el efecto de cualquier proceso morfológico se reduce simplemente a la determinación de cuales pixeles del primer plano van al segundo plano y viceversa.
- **Elementos estructurales y vecindades:** Un elemento estructurante es un arreglo rectangular de pixeles de valores 1 o 0. Tienen un pixel central el cual está localizado en el verdadero centro cuando ambas dimensiones son impares. Veamos las operaciones básicas de morfología. Estas son erosión y dilatación. Todas las otras operaciones morfológicas pueden ser definidas en términos de estos operadores primitivos.
- **Erosión:** para realizar una erosión de una imagen binaria, sucesivamente pasamos el pixel central del elemento estructural sobre los pixel del primer plano (valor 1). Si alguno de los pixeles vecinos tienen valor cero por pertenecer al pixel del segundo plano, entonces el pixel del primer plano es cambiado al segundo plano.

- **Dilatación:** para realizar una dilatación de una imagen binaria, sucesivamente pasamos el pixel central del elemento estructural sobre los pixel del segundo plano (valor 0). Si alguno de los pixeles vecinos tienen valor uno (1) por pertenecer al pixel del primer plano, entonces el pixel del segundo plano es cambiado al primer plano.
- **Veamos los ejemplos de Matlab, ejemplo de dilatación:**

```
A=imread('texto.png');
bw=im2bw(A);
subplot(1,2,1), imshow(bw), title('imagen original');
se=[0 1 0; 1 1 1; 0 1 0];
bwout=imdilate(bw, se);
subplot(1,2,2), imshow(bwout), title('imagen dilatada');
```




Figura 25: Imagen binaria original y dilatada respectivamente
(Fuente: elaborado por el autor)

```
A=imread('texto.png');
bw=im2bw(A);
subplot(1,2,1), imshow(bw), title('imagen original');
se=ones(6,1);
bwout=imerode(bw, se);
subplot(1,2,2), imshow(bwout), title('imagen erosionada');
```

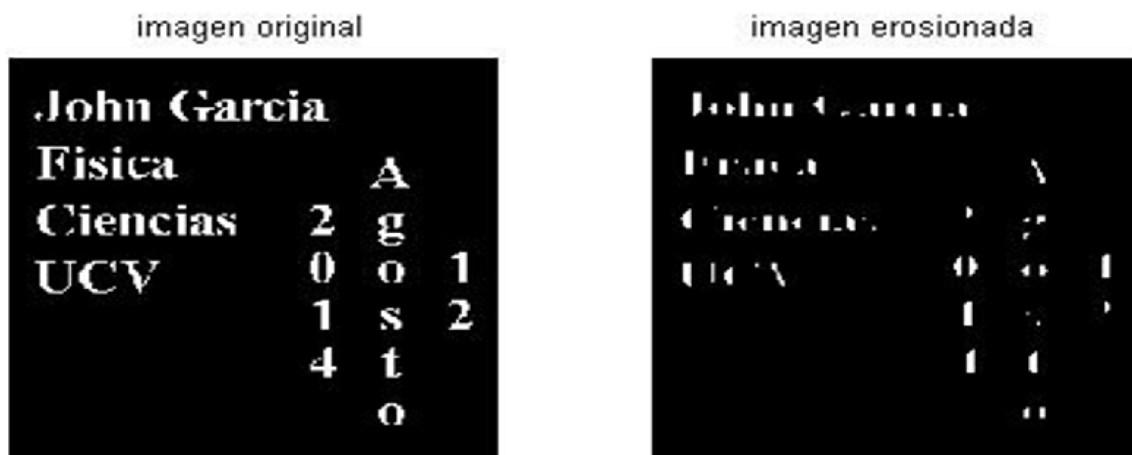


Figura 26: Imagen binaria original y erosionada respectivamente
(Fuente: elaborado por el autor)

- **Efectos y usos de la erosión y la dilatación:** es aparente que la erosión reduce el tamaño del objeto binario, mientras la dilatación lo incrementa. La erosión tiene el efecto de remover pequeñas estructuras aisladas, uniendo regiones en una característica y el de reducir el tamaño de objetos solidos erosionándolos hasta el borde. La dilatación tiene aproximadamente el mismo efecto, engrosando o adelgazando regiones estrechas y dilatando las características alrededor de sus bordes.
- **Extracción de frontera:** podemos definir el límite de un objeto primero erosionándolo con un elemento de estructura pequeño y adecuado, y entonces substrayendo el resultado de la imagen original.

```
A=imread('8bn.png');
bim=imerode(A,se);
se=strel('disk',15); bw1=A-bim;
subplot(1,3,1), imshow(A), title('imagen original');
subplot(1,3,2), imshow(bw),title('imagen erosionada');
subplot(1,3,3), imshow (bw1),title('borde imagen
original restada de la erosionada');
```



Figura 27: Foto 8 segmentada en binaria original y luego la original erosionada usando un disco de radio 15 como elemento estructurante. Por último, la imagen original restada a la erosionada respectivamente (Fuente: Dra. De Santis, UCV, Caracas Venezuela)

2.11 Segmentación de Imágenes: Segmentar es dividir una imagen digital en varias partes (grupos de píxeles) u objetos. La Segmentación se usa tanto para localizar objetos como para encontrar los límites de estos dentro de una imagen. Aquí se le asigna una etiqueta a cada píxel de la imagen de forma que los píxeles que compartan la misma etiqueta también tendrán ciertas características visuales similares.

- **Uso de las propiedades y características de la imagen en la segmentación:** hay tres propiedades y características bases en las imágenes las cuales pueden ser explotadas para ayudarnos a la segmentación: color, textura y movimiento.
- **Intensidad de la umbralización:** la idea básica del uso de la intensidad de la umbralización en la segmentación es muy simple. Escogemos algún valor de umbral tal que los pixeles con valores superiores que dicho umbral se asignen a una región, mientras que aquellos que caen por debajo de dicho umbral son asignados a otra región adjunta.
- **El Método de Otsu:** es un método de aproximación a la umbralización automática que está basado en un relativo y sencillo análisis el cual encuentra aquel umbral que minimiza la varianza dentro de la clase de los umbralizados pixeles blancos y negros. En otras palabras, esta aproximación selecciona aquel umbral que resulta en el agrupamiento más cerrado de dos grupos representados por los pixeles de primer plano y de fondo.

```
I=imread('prueba3.jpg');
subplot(2,2,1), imshow(I), title('imagen original');
subplot(2,2,2), im2bw(I,0.35), title('manual threshold');
B=im2bw(I,0.35); [counts,X]=imhist(B);
P=polyfit(X,counts,6); Y=polyval(P,X);
[V,ind]=sort(abs(diff(Y))); thresh=ind(1)./255;
subplot(2,2,3), im2bw(I,thresh), title('Polynomial
thereshold'); level=graythresh(I);
subplot(2,2,4), im2bw(I,level), title('metodo Otsu');
figure; plot(X,counts); hold on, plot(X,Y,'r');
```




Figura 28: Imagen original, luego con umbralización manual, polinómica y por el método Otsu respectivamente
(Fuente: Medical Image Analysis Center – MIAC, <https://miac.unibas.ch/miac/>)

- **Crecimiento de regiones y división de regiones (splitting):** crecimiento de regiones es una aproximación a la segmentación en el cual los píxeles son agrupados en grandes regiones basadas sobre la similitud de acuerdo a criterios predefinidos de similitud. Para ello es necesario considerar la relación de adyacencia espacial entre píxeles. Los criterios de similitud son relacionados a su intensidad, color o propiedades de relación estadística sobre su propia vecindad.
- **Algoritmo de división y fusión:** el algoritmo se divide en dos sucesivos estados. Los cuatro pasos básicos son:
 - Considerar la imagen como un todo a ser el área inicial de interés.
 - Ver el área de interés y decidir si todos los píxeles contenidos en la región satisfacen algún criterio de similitud.
 - Si es VERDADERO, entonces el área de interés (también llamado bloque) corresponde a la región en la imagen y es etiquetada.
 - Si es FALSO, entonces se divide el área de interés (usualmente en cuatro sub-reas iguales) y se considera cada una de las sub-áreas como el área de interés de turno.

```
close all
clear all
clc
```

```
B=imread('foto_3.jpg'); subplot(1,3,1), imshow(B), title
('Foto 3 original');
C = imresize(B, [256 256]);
Bbw=im2bw(C);
I=Bbw;
S=qtdecomp(I, .17);
blocks=repmat(uint8(0), size(S));
for dim=[512 256 128 64 32 16 8 4 2 1];
numblocks=length(find(S==dim));
if (numblocks>0)
values = repmat(uint8(1), [dim dim numblocks]);
values(2:dim, 2:dim, :)=0;
blocks=qtsetblk(blocks, S, dim, values);
end
end
blocks(end, 1:end)=1;
blocks(1:end, end)=1;
subplot(1,3,2), imshow(I); title ('Foto 3 en blanco y
negro');
k=find(blocks==1);
A=I; A(k)=255;
subplot(1,3,3), imshow(A); title ('Foto 3 en división y
fusión');
```



Figura 29: Foto 3 en original, luego en blanco y negro y luego en división y respectivamente
(Fuente: Dra. De Santis, UCV, Caracas Venezuela)

Tipos de Segmentación.

- **Segmentación por Watershed**
- Watershed es un método de crecimiento de regiones, que mediante la inundación de los valles, es capaz de reconocer los contornos de zonas similares, rodeadas por cadenas de máximos y mínimos. La transformada Watershed, T.W., es un método de segmentación basado en regiones. Este método clasifica los píxeles según su proximidad espacial, el gradiente de sus niveles de gris y la homogeneidad de sus texturas. Con el objeto de segmentar una imagen en niveles de gris, previo a la aplicación del método “Watershed”, a través de su gradiente, se obtiene una imagen donde los niveles de los contornos de los objetos a segmentar representan una zona de elevada intensidad de gris. Las zonas de baja intensidad de gris darán lugar a las vasijas o “basins” por donde fluirá el agua e inundará la topografía de la imagen. Las elevaciones en los niveles de gris generadas por los contornos permanecerán y darán lugar a la segmentación de la imagen mediante las líneas Watershed resultantes. Veamos de forma gráfica como opera la segmentación por Watershed.

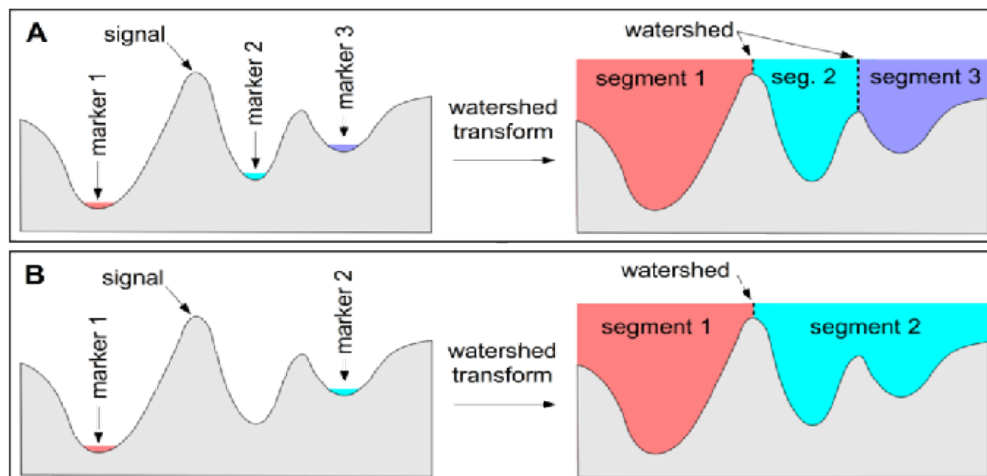


Figura 30: Explicación gráfica de cómo funciona la segmentación por watershed
(Fuente: Solomon & Breckon, *Fundamentals of Digital Image*, págs.279)

```
A=imread('overlapping_euros.jpg');
Agrad=ordfilt2(A,25,ones(5))-ordfilt2(A,1,ones(5));
figure, subplot(1,3,1), imshow(A,[]);
subplot(1,3,2), imshow(Agrad,[]);
L = watershed(Agrad); rgb = label2rgb(L, 'hot', [.5 .5 .5]);
subplot(1,3,3), imshow(rgb, 'InitialMagnification', 'fit');
```



Figura 31: Cálculo directo del operador Watershed sobre el gradiente de imágenes resultando en sobre segmentación
(Fuente: Solomon & Breckon, Fundamentals of Digital Image, págs.282)

Segmentación por análisis de histogramas

- Este método de segmentación es el más eficiente en comparación con otros métodos de segmentación de la imagen, pues solo requiere una pasada por la imagen. Recordemos que un histograma es una representación gráfica de una variable en forma de barras, donde la superficie de la barra es proporcional a la frecuencia de los valores representados. En el eje vertical se representan las frecuencias, y en el eje horizontal los valores de las variables. En esta técnica, un histograma se calcula a partir de todos los píxeles de la imagen, y los picos y los valles en el histograma se utilizan para localizar los grupos en la imagen. Picos: a menudo indican la presencia de zonas homogéneas. Valles: establecen los umbrales de separación. Los pasos para realizar este tipo de segmentación son:
 - Extraer en el histograma para la imagen en cuestión.
 - Analizamos los ruidos en la imagen que corresponden a los falsos mínimos y falsos máximos.
 - Luego aplicamos un filtro de mediana sobre el histograma para tratar de eliminar los falsos mínimos y falsos máximos. Luego consideramos los picos como el número de

objetos presentes en nuestra imagen y el umbral de separación entre dos clases como la media suma de sus picos.

Segmentación por Clustering

- La Segmentación por Agrupamiento (Clustering), es útil cuando no se conocen las características de las regiones que buscamos o, incluso, si no se sabe cuántas categorías hay. Se fundamenta en que cada región del espacio de características se define mediante un patrón o centroide. Cada vector de características se asigna a la región del centroide más próximo. Primero se busca el agrupamiento neutral en una data multidimensional empleando una medida de similaridad o disimilaridad. Las clases son desconocidas y sacadas de la data misma. La data se divide en grupos similares. La clasificación las asigna a uno de los grupos conocidos. Uno de los algoritmos de segmentación por Clustering es el algoritmo de K-means.

Algoritmo del K-Means

- K-means (MacQueen, 1967) es uno de los más simples algoritmos de aprendizaje no-supervisados que resuelve el muy bien conocido problema de agrupamiento. El procedimiento sigue un camino simple para clasificar una data dada a través de un cierto número de clúster (asumimos k clústeres) fijados a priori. La idea principal es el definir K centroides, una para cada clúster. Estos centroides deben ser colocados en una astuta manera porque localización diferente ocasiona resultados diferentes. Entonces, la mejor manera es colocarlos tan lejos como sea posible el uno del otro. El siguiente paso es tomar cada punto perteneciente a unos datos dados y asociarlos al centroide más cercano. Cuando ningún punto se encuentre pendiente, el primer paso se ha completado y el primer grupo está listo. A este momento necesitamos recalculamos k nuevos centroides como baricentros de los clústeres resultantes del paso previo. Luego que tengamos estos k nuevos centroides, un nuevo vínculo ha sido hecho entre los puntos de la misma data y los nuevos centroides más cercanos. Un lazo ha sido generado. Como resultado de este lazo podemos notar que los k centroides cambian su locación paso a paso hasta que ningún cambio sea hecho. En otras palabras, los centroides no se mueven más.
- La función objetiva es: $J = \sum_{j=1}^k \sum_{i=1}^x \|x_i^{(j)} - C_j\|^2$

- dónde $\|x_i^{(j)} - C_j\|^2$ es una distancia escogida medida entre un punto de la data $x_i^{(j)}$ y el clúster central C_j , es un indicador de la distancia de la n puntos de la data desde sus clústeres centrales respectivos.
- El algoritmo está compuesto de los siguientes pasos:
- Inicializar el número de clases; k y centroides μ_j
- Asignar un pixel a la clase o grupo cuyo centroide está cerca, en el aspecto del espacio n -dimensional.
- Luego que todos los pixeles han sido asignados recalcular los centroides.
- Repetir los pasos 2 y 3 hasta que ver que todos los centroides no cambien (convergen).




Figura 32: Ejemplo gráfico de cómo opera el algoritmo del K-means para la segmentación
(Fuente: Solomon & Breckon, Fundamentals of Digital Image, págs.293)

CAPÍTULO 3

DINÁMICA FÍSICA DE LOS CRECIMIENTOS TUMORALES Y ANÁLISIS DE ESCALAMIENTO

El desarrollo y la vida saludable de un ser humano requieren la cooperación de más de diez millones de células para el bien de nuestro organismo. Esta cooperación es mantenida por señales y comprobaciones celulares las cuales determinan cuando la célula debe dividirse, morir o diferenciarse. La más básica definición es que el tumor o cáncer es el colapso de esta cooperación. Este resultado egoísta de un crecimiento descontrolado de las células es lo que lleva eventualmente a la muerte al organismo. Se piensa comúnmente que el cáncer es una enfermedad del ADN. Esto es, un crecimiento descontrolado de células viene como resultado de la alteración o mutación en el material genético. De allí que la mayoría del tratamiento está orientado en la biología del cáncer. Sin embargo, otra aproximación al estudio del desarrollo y progreso del cáncer ha emergido y está incrementándose su importancia y es la oncología física y matemática la cual usa técnicas físico-matemáticas y computacionales para estudiar como las células del cáncer se generan, crecen y evolucionan [6]. Veamos algunos conceptos en esta área.

El crecimiento tumoral es un proceso complejo que depende de la proliferación y difusión de las células tumorales en los tejidos del huésped. La búsqueda del mecanismo subyacente del desarrollo y progresión tumoral ha sido ampliamente enfocada sobre las cuentas de los cambios moleculares para el fenotipo maligno a nivel celular, mientras nuestro conocimiento sobre la dinámica del crecimiento tumoral permanece escaso. En parte, esto se debe a las dificultades en desarrollar herramientas capaces de describir procesos de crecimiento asociados con fenómenos desordenados. Como muchos objetos naturales, las colonias celulares parecen ser fractales [7], y una descripción de su muy complejo y variado contorno usando geometría clásica euclidiana es muy difícil de lograr. Sin embargo, el contorno del objeto puede proveer una indicación valiosa acerca de su comportamiento dinámico, y la naturaleza fractal del contorno de las colonias de células o tumores con una escala invariante nos permiten usar el análisis de escalamiento para lograr dicha descripción.

Una importante implicación de la simetría espacial y temporal del tumor es que ciertas cantidades universales (llamadas exponentes críticos) pueden ser definidas las cuales permiten la caracterización de la dinámica del crecimiento tumoral. Sucesivamente esto permite determinar el principal mecanismo físico responsable para el proceso de crecimiento.

El análisis y entendimiento del crecimiento tumoral ha sido objeto de multidisciplinarias investigaciones. En las últimas décadas se ha publicado un gran número de complejos modelos físico-matemáticos, con diferentes aproximaciones debidas a su naturaleza multiescalar. El crecimiento se supone ser exponencial, gompertziano o logístico [8]. La visión corriente de la cinética del crecimiento tumoral está basada sobre la suposición general que las células del tumor crecen exponencialmente [7]. Este modelo es llamado “régimen de crecimiento Gompertziano” y está basada en la opinión que los tumores crecen en función de la búsqueda de nutrientes. Viene dado por la siguiente ecuación:

$$\frac{X}{X_0} = e^{\frac{A}{\alpha}(1-e^{-\alpha t})}$$

Donde X = tamaño del tumor, en sus apropiadas unidades; a cualquier tiempo t , y X_0 = tamaño inicial del tumor y A y α son constantes. Tal cinética coincide con la ilimitada actividad proliferativa de las células tumorales en estudios in vitro. Sin embargo, algunas características permanecen pobremente explicados y están en desacuerdo con un régimen exponencial de proliferación celular. Por ejemplo, tales modelos no consideran el arreglo espacial de las células a una localización anatómica específica, o la extensión espacial de las células cancerosas. Estos aspectos espaciales son esenciales en la estimación del crecimiento tumoral dado que ellas determinan la invasividad del tumor [8].

Antonio Brú en 1998 describió matemáticamente la dinámica del crecimiento de colonias derivadas de una línea de células tumorales (astrocito de rata glioma C6), la cual levantó dudas razonables acerca de la teoría exponencial de proliferación celular [7]. Los resultados presentan una dinámica de crecimiento que no son compatibles con la idea del Gompertziano sino con el modelo de Molecular Beam Epitaxy (MBE - crecimiento epitaxial por haces moleculares) donde se implica un crecimiento lineal apoyado en la idea de que la célula en cuestión se desplaza en función de la difusión celular. Este modelo

describe el proceso de crecimiento dominado por difusión y deposición en la superficie, como la de un cristal en crecimiento. Esta clase de universalidad ha sido encontrada en algunos modelos de deposición [9]. La ecuación del continuo que describe esta clase de universalidad es:

$$\frac{\partial h(x, t)}{\partial t} = -K \frac{\partial^4 h(x, t)}{\partial x^4} + F + \eta(x, t)$$

Donde $h(x, t)$ es la posición sobre el tumor o borde de la colonia celular, K es el coeficiente de difusión superficial (la cual es independiente del exponente crítico), F es la tasa de crecimiento, y $\eta(x, t)$ es el ruido aleatorio.

El análisis de escalamiento es una técnica que explota las propiedades geométricas de los frentes de crecimiento usando diferentes conceptos de la teoría de los procesos estocásticos y la geometría fractal. Estos métodos han sido aplicados a la interfaz del tumor, lo cual indica que el comportamiento de las fluctuaciones guía la ecuación de evolución estocástica, la cual es analizada bajo simetría radial [8].

ANÁLISIS DE ESCALAMIENTO

Para estudiar los tumores desde el punto de vista físico y matemático se aborda el tumor o la lesión como dotada de una interfaz rugosa. La rugosidad es una útil medida cuantitativa de la irregularidad de una interfaz. La forma del tumor nos permite estudiar y clasificar el tipo de tumor de acuerdo a su geometría y dinámica. La forma del contorno es una valiosa indicación del comportamiento de la dinámica del tumor, algo que ya ha sido observado en células tumorales. La forma del contorno celular determina el número y tipo de canales de intercambio celular. Por otra parte, la morfología de una simple célula puede determinar su naturaleza maligna como lo dice Losa [9]. Este resultado ha sido extrapolado al caso de los tumores para predecir su naturaleza maligna. Los tumores presentan una frontera irregular cuyas propiedades geométricas pueden variar según el grado de malignidad. Evaluando esta irregularidad por medio de diversas metodologías de segmentación de imágenes se logra definir con precisión la región activa del tumor y su frontera [10].

Existen diversos trabajos [7, 9] donde la dimensión fractal de los tumores ha sido medida con el objetivo de clasificarlas y determinar su naturaleza maligna. Por otro lado, ha habido diferentes intentos de construir un modelo matemático describiendo el crecimiento tumoral, pero ellos son muy restrictivos en sus hipótesis. Brú, propuso un modelo

matemático puramente descriptivo derivado del estudio de la evolución temporal del crecimiento tumoral. En este modelo para caracterizar morfológicamente los tumores se usa el algoritmo del conteo de cajas.

La primera condición que debe cumplirse para aplicar las técnicas de análisis de escalamiento es que la dinámica de crecimiento de un proceso corresponda a la naturaleza fractal de la interface. Para ello calculamos la dimensión fractal o de Hausdorff. Se calcula por el algoritmo de conteo de cajas (box-counting) originalmente propuesto por Russel [8]. Consiste esencialmente en contar el número de cajas que contiene una estructura y establecer una ley potencial entre este número y el tamaño de la caja o escala “e”. N (e) es el número de cajas necesarias para cubrir completamente una estructura.

$$df = - \lim_{e \rightarrow 0} \frac{\log[N(e)]}{\log(e)}$$

Para describir la dinámica del crecimiento tumoral estudiamos la invariancia en escala del comportamiento de la interfaz tumoral. La dinámica de muchos sistemas físicos que exhiben interfaces rugosas puede ser caracterizada por **un grupo o conjunto de exponentes críticos** obtenidos de las propiedades de invariancia en escala de ciertos parámetros geométricos de la interfaz tumoral [9]:

El primero de ellos es el radio medio del tumor, el momento de primer orden de la posición de la interface, $\langle r \rangle = N^{-1} \sum_{i=1}^N r_i(t)$ donde N es el número de puntos de la interface del tumor y r_i es la distancia de estos puntos desde el centro de la masa del tumor. Este se desarrolla en el tiempo y nos provee la velocidad de crecimiento del tumor.

La siguiente cantidad importante es el momento de segundo orden de la posición de la interface como una función del arco de longitud l y el tiempo t: $w(l, t) = \left\{ \frac{1}{l} \sum_{r_i \in l} [r_i(t) - \langle r_i \rangle_l]^2 \right\}_L^{1/2}$ donde $\langle * \rangle_l$ significa el promedio local de los subgrupos de arcos de longitud l, y $\{ * \}_L$ es el promedio sobre todo el sistema. Esta cantidad mide **el ancho de la interface** y provee una medida de las fluctuaciones locales de la interface alrededor de su valor local medio. Un sistema con simetría circular muestra insignificantes fluctuaciones comparados con el tamaño del sistema que se comportan como un sistema lineal con un tamaño dependiente del tiempo. Este resultado ha sido probado usando diferentes métodos para determinar los exponentes críticos. La función ancho de esta

interface rugosa, dependiente del tamaño del sistema L y del tiempo t , muestra una conducta de escalamiento: $w(L, t) = \begin{cases} t^\beta & \text{si } t \ll t_s \\ L^\alpha & \text{si } t \gg t_s \end{cases}$ con α como el exponente de rugosidad, β el exponente de crecimiento (el desarrollo en el tiempo del ancho de la interface) y t_s es el tiempo de saturación para el cual la longitud de correlación lateral l_c alcanza y supera el tamaño L del sistema y escala como L^z , siendo z el exponente dinámico. Estos tres exponentes críticos están relacionados a través de $z = \alpha/\beta$, como en geometría lineal. Este exponente dinámico z , está relacionado a la correlación del tiempo de la interface. El significado físico de este exponente está relacionado con la celeridad por la cual la información acerca de un punto creciendo sobre la interface es transmitido a través de la interface.

Aunque esta descripción es válida para una gran variedad de sistemas físicos, existen algunos casos en los cuáles no son válidos. Cuando el ancho local $w(l, t)$ difiere del ancho global $w(L, t)$, podemos definir α_{loc} y α_{glob} , el exponente local y global, respectivamente como: $w(l, t) \sim l^{\alpha_{loc}}$, y $w(L, t) \sim L^{\alpha_{glob}}$, $t \gg t_s$ siendo L toda la longitud del contorno de la interface circular [9].

En conclusión, estos exponentes están relacionados a la geometría del sistema, cuantificando la rugosidad en dos escalas: a pequeñas escalas del sistema tenemos el exponente crítico de rugosidad local α_{loc} y a escalas del sistema tenemos el exponente crítico de rugosidad global α_{glob} . Finalmente, cuando el desarrollo de la interface es anómala desde un punto de vista dinámico, se define otro exponente crítico de crecimiento β^* , el cual describe esta anomalía en el tiempo. Determinando este set de 5 exponentes, los cuales no son independientes, la dinámica de la interface puede ser conocida así como el principal mecanismo responsable del crecimiento. Dentro del alcance de este trabajo, solamente el exponente de rugosidad local puede ser determinado ya que sólo se cuenta con información en un instante de tiempo en particular. Si se quiere determinar la dinámica de crecimiento en forma completa se hace necesario obtener muestras temporales en número suficiente.

Como parte del análisis de escalamiento también se calcula la dimensión fractal de capacidad o dimensión de Hausdorff, df , la cual se encuentra asociada con el exponente de rugosidad local: α_{loc} mediante la relación [8]: $df + \alpha_{loc} = d_E$ donde: d_E es la dimensión

Euclídea del espacio que contiene la interfaz del tumor. La evaluación de la dimensión fractal se realiza mediante el algoritmo de conteo de cajas [11], mediante el cual el espacio Euclídeo que contiene la estructura a evaluar se divide en cajas (volúmenes) para una escala o tamaño específico y se cuenta el número de cajas que contiene a la estructura.

CAPÍTULO 4 METODOLOGÍA

4.1 Adquisición de las Imágenes:

Agradecemos a la doctora Mayerith Torreyes quien funge como Médico Dermatólogo en el Hospital Militar Dr. Carlos Arvelo. Ella aportó un grupo de veinte (20) imágenes de lesiones de piel obtenidas de sus pacientes. La obtención de las imágenes fue realizada utilizando como equipo de diagnóstico un dermatoscopio. Este equipo, el video dermatoscopio computarizado con luz polarizada, (FotoFinder dermoscope®, TeachScreen Software, Bad Birnbach, Germany), utiliza un sistema óptico con factores de magnificación de 20 a 70x. Para la realización de este proyecto solo se utilizaron imágenes dermatoscópicas que abarcaban la lesión de la piel en cuestión. En estas imágenes se seleccionaron regiones de interés (ROI). Las ROI (imágenes dermatoscópicas) que fueron adquiridas por el dermatoscopio están en formato JPEG 24 bits en el espacio RGB (Red, Green, Blue) y con un tamaño de 768 X 576 pixeles. El análisis y procesamiento de todas las imágenes a utilizar fue realizado por medio de algoritmos ambientados en MATLAB, el cual es bastante eficaz para el procesamiento de imágenes.




Figura 33: Foto dermatoscópica de la lesión de piel del paciente 8, 7, 14 y 19 respectivamente. (Fuente: Dra. Mayerith Torreyes, Médico Dermatólogo, Hospital Militar Dr. Carlos Arvelo)

Imágenes dermatoscópicas.

Fig. 33a) Asimetría, red de pigmentos atípica, pigmentación irregular y proyecciones.

Fig. 33b) Asimetría, pigmentación irregular, color rosa, proyecciones y regresión.

Fig. 33c) Lesión simétrica, glóbulos marrones y puntos negros de distribución regular.

Fig. 33d) Patrón homogéneo. Coloración gris azul

4.2 Pre procesamiento - Segmentación :

Para conseguir segmentar la imagen utilizamos un algoritmo construido por el Profesor Wuilian Torres [12] del Centro de Procesamiento Digital de Imágenes del Instituto de Ingeniería y Laboratorio CGGA UCV el cual comienza con el enmascaramiento de pelos y del borde de la imagen, hace un filtrado morfológico, determina los umbrales y así segmenta la lesión.

Lo primero que hace este algoritmo es reducir la presencia de pelos que traen algunas lesiones mediante filtros morfológicos y la aplicación del operador bottom-hat (alas del sombrero) con un elemento estructurante de dimensión 7x7 en el espacio RGB para destacar los elementos que presentan un color oscuro. Luego, sobre este resultado, se toma el valor máximo entre los tres canales; se establece un umbral y se consideran los elementos que presentan forma alargada para generar una máscara de los pelos presentes en la imagen. Para restaurar los colores de los píxeles dentro de la máscara de pelos, se utiliza un filtro de mediana. En cada etapa de esta metodología haremos el seguimiento de un caso, el cual será de la lesión 14. La Figura 34 presenta el resultado de este procesamiento sobre la imagen mostrada en la Fig. 33c o lesión 14. Este algoritmo puede ser solicitado al profesor Wuilian Torres.




Figura 34: Detección de pelos y enmascaramiento después de aplicar el filtro morfológico Bottom-Hat.
(Fuente: Torres, Wuilian; Facultad de Ciencias, UCV)

Se utilizó un filtro morfológico para reducir la variabilidad local de la imagen pero conservando los bordes de los elementos presentes.

4.3 Procesamiento – Obtención de Borde:

Ya teniendo las 20 lesiones segmentadas y convertidas en máscara binaria se procedió a la obtención del borde. Para ello se usó un algoritmo que actúa sobre las imágenes binarias (máscaras). Este algoritmo preserva las características geométricas de la interfaz. Esencialmente consiste en la aplicación de una máscara de filtro 3 x 3 sobre cada una de las imágenes previamente segmentadas. La máscara de filtro actúa como sigue: si el pixel central de la máscara 3x3 es parte de la imagen segmentada entonces se realiza una suma sobre todos los píxeles dentro de la máscara 3 x 3, asignándole valor uno si el pixel pertenece a la imagen segmentada, de otra manera, se le asigna cero. Si la suma sobre máscara es menos que 9, el pixel central de la máscara 3x3 pertenece a la interfaz del tumor. El resultado final es una imagen binaria 2D incluyendo los pixeles de la interfaz, la cual ha sido inspeccionada para seleccionar aquellos contornos relacionados a la interfaz del tumor solamente. El diagrama de flujo se muestra en la fig. 35. Como ejemplo en la fig. 36a mostramos una imagen de la lesión segmentada y luego en la fig. 36b el borde obtenido usando el algoritmo propuesto.




Figura 35: Diagrama de Flujo para el algoritmo especial de detección de la interfaz tumor-huésped. Los píxeles son aceptados cuando: el pixel central de la máscara de filtro 3x3, pertenece a la imagen segmentada y la suma S sea menor que 9.

(Fuente: Torres Hoyos & Martín Landrove, *Physica A* 391 (2012) 1195-1206)

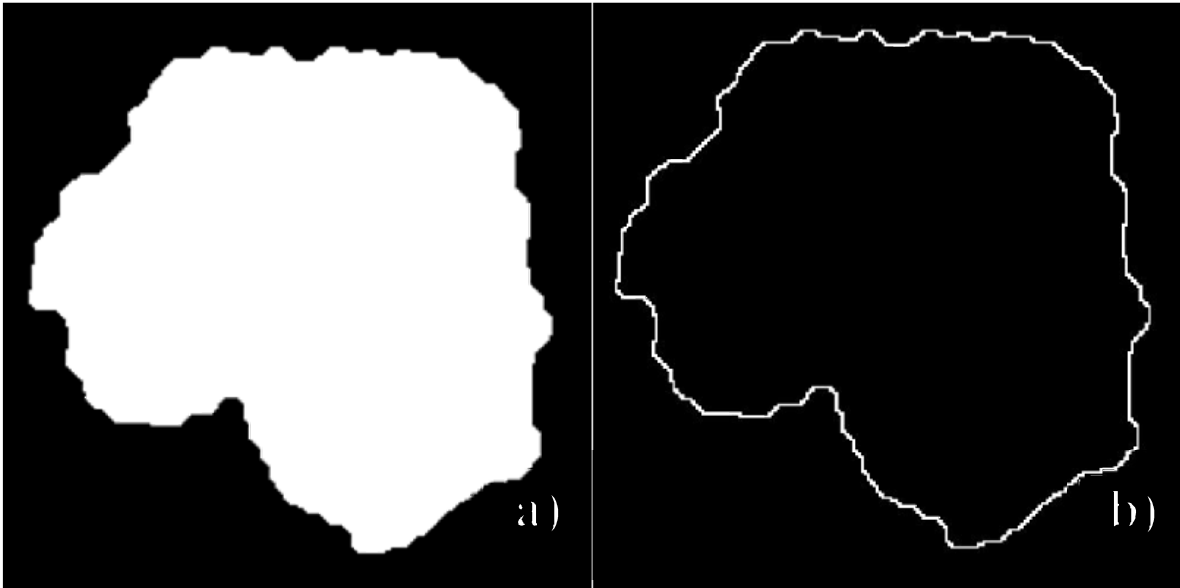


Figura 36. a) Imagen Binaria de la lesión 14 Segmentada y b) borde calculado de la interface del tumor calculado a partir del algoritmo presentado en este trabajo.

4.4 Cálculo de la Dimensión Fractal:

En el momento que la interfaz del tumor exhibe geometría fractal [13], es relevante el calcular la dimensión fractal, d_f . Esta dimensión se calcula frecuentemente por el algoritmo de conteo de cajas que fue propuesto originalmente por Russel [11], el cual esencialmente cuenta el número de cajas que contienen la estructural y establece una ley de potencias que relaciona este número y el tamaño o escala ϵ de la caja, tal que la dimensión fractal puede ser estimada por la siguiente relación [8]:

$$df = - \lim_{\epsilon \rightarrow 0} \frac{\log[N(\epsilon)]}{\log(\epsilon)} \quad (\text{Ec. 4.1})$$

donde $N(\epsilon)$ es el número de cajas necesarias para cubrir completamente la estructura fractal. De acuerdo a la referencia anterior hay una relación entre la dimensión fractal y el exponente local de rugosidad y viene dado por:

$$df + a_{loc} = d, \quad (\text{Ec. 4.2}):$$

donde d es la dimensión euclídea del espacio donde la estructura fractal está colocada. La ecuación anterior es general y puede ser usada para constatar la certeza del estimado de df y α_{loc} . La figura 37 muestra un ejemplo de la aplicación del conteo de cajas para la determinación de la dimensión fractal para la lesión 14 a la cual venimos haciendo seguimiento. El algoritmo usado puede ser revisado en el apéndice IV.

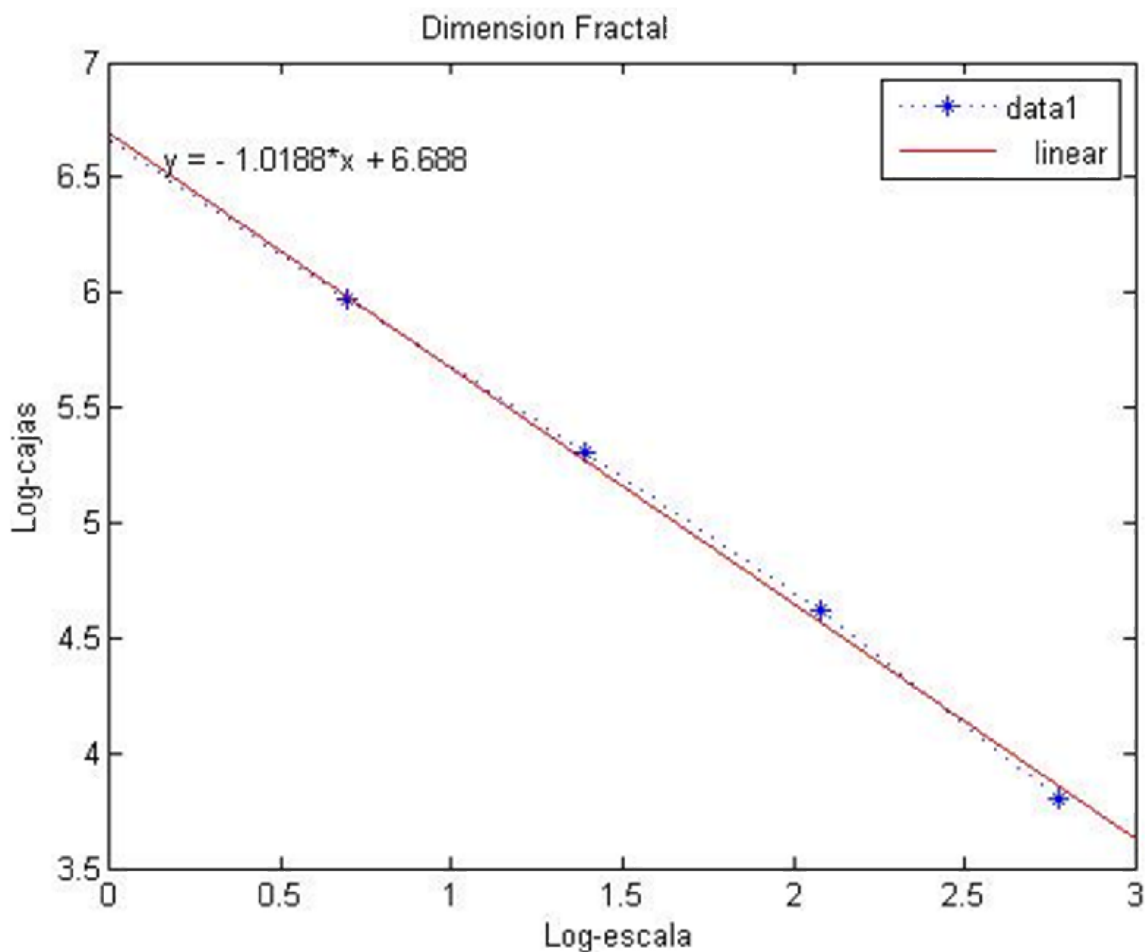


Figura 37 Dimensión Fractal obtenida para la lesión de piel nº 14 calculada con el algoritmo de conteo de cajas, $N(e)$ es el número de cajas y “ e ” es el tamaño de dicha caja. El valor obtenido para la dimensión fractal es $df= 1,018$

4.5 Análisis de Escalamiento: En este trabajo dado su alcance de escalas pequeñas y que los datos que se tienen corresponden a un instante de tiempo particular y dado que se usan los datos de una imagen en dos dimensiones, se usó la primera descripción que trabaja con el perímetro total y la longitud de arco respectivamente. Para evaluar el exponente de rugosidad local, la interface total del tumor-anfitrión Σ es completamente ejemplificada usando círculos como se muestra en la Fig. 38.




Figura 38 Ancho de la Interface de un tumor-huésped, El ancho de la Interface es calculado para sectores con un arco de longitud l. Para cada arco de longitud de arco, el valor medio de la interface y de las fluctuaciones alrededor de ella es calculado para obtener el correspondiente ancho de la interface. Para un dado valor de la longitud del sector, todos los valores del ancho de la interface son promediados para obtener el valor final del arco de longitud l, $w(l, t)$. El comportamiento de la ley potencia de $w(l,t)$ versus l provee el exponente de rugosidad local

Para cada muestra, los puntos de la interface determinan un ángulo y correspondientemente un arco de longitud. El promedio de este arco de longitud determina el arco de longitud “l” que corresponde al tamaño seleccionado de la circunferencia de muestra, y la ecuación usada para $w(l)$ es:

$$w(l, t) = \left\{ \frac{1}{l} \sum_{r_i \in l}^N [r_i(t) - \langle r_i \rangle_l]^2 \right\}_L^{1/2} \quad (\text{Ec. 4.4}).$$

El comportamiento de la ley de potencia de esta ecuación observada a pequeños valores de “l” se reduce a:

$$w(l) \sim l^{\alpha_{loc}} \quad (\text{Ec. 4.5})$$

Donde α_{loc} es el exponente de rugosidad local [9, 7]. Notemos que la evolución temporal no es considerada dado que los datos del tumor exhiben una evolución temporal que no puede ser estimada certeramente, y en una gran variedad de casos es desconocido, por lo cual una alternativa variable puede ser considerada y ella es el definirlo histológicamente por medio del grado del tumor [14]. Se asume que para tumores del mismo origen histológico, similares grados del tumor corresponden a similares estados dinámicos y por consiguiente muestran valores comunes del exponente α_{loc} .




Figura 39 Comportamiento de $W(l)$ como está descrito en la ecuación 4.4. La pendiente de la ley

En la figura 39 se muestra el comportamiento de $w(l)$ para los tumores de piel. Un análisis de la figura revela que $W(l)$ exhibe un comportamiento de ley potencial a escalas pequeñas

como se predice en la ecuación correspondiente, y también un valor de saturación asintótico, $W(\Sigma)$, donde Σ es la longitud total del arco de longitud o perímetro de la interface huésped-tumor o su equivalente $W(2\pi)$.

4.6 Validación del método de cálculo:

El cálculo de la ecuación 4.4 requiere que se cumplan ciertos criterios para lograr una segura y certera determinación de α_{loc} . Primero debemos considerar el efecto de las muestras discretas de la interface tumor-anfitrión sobre la evaluación de la ecuación 4.4. La naturaleza discreta de la matriz de la imagen impone un límite para el cálculo de $w(l)$. Los radios de los círculos de muestra deben ser apropiadamente seleccionados para evitar algunos artefactos debidos a la discreticidad de la matriz de la imagen. El tamaño del pixel nos da una escala mínima para el muestreo de imagen. El radio mínimo del círculo de muestra que se escoge es aquel círculo cuya área es igual al área del pixel de la imagen, esto es:

$$R_{min} = \left(\frac{1}{\pi}A\right)^{\frac{1}{2}} \quad (\text{Ec. 4.6})$$

Donde A es el área del pixel. La fig. 40 muestra como la ecuación 4.4 fluctúa cuando cambian los radios de los círculos de muestra.




Figura 40 Comportamiento de $W(l)$ con el arco de longitud subtendido por los puntos de la interface de los círculos de muestra.

Cuando el cálculo de la ecuación 4.4 está limitado solo a los círculos de muestra de radios mínimos, el artefacto procedente del carácter discreto de la matriz de la imagen se revela de forma clara, como se representa en la figura 40. Una manera de vencer el efecto del carácter discreto de la matriz de la imagen es el eliminar la contribución de los radios de los primeros círculos de muestra del cálculo de la ecuación 4.4. Este procedimiento fue consistentemente realizado para todos los cálculos presentados en este trabajo. El segundo aspecto a considerar es el efecto del tamaño de los datos sobre el cálculo del exponente local de rugosidad α_{loc} . Interfaces pequeñas anfitrión-tumor exhiben más incertidumbre en la evaluación del promedio presente en la ecuación 4.4. Para determinar el tamaño crítico, el método fue aplicado a interfaces simuladas usando círculos de diferentes diámetros, y como consecuencia, diferentes números de puntos de los datos, y solo $w(2\pi)$ fue calculado, es decir, el valor de saturación de la ecuación 4.4. En principio, $w(2\pi)$ debería tener el mismo valor dado que el ancho de la interfaz solo depende del carácter discreto de la matriz de imagen y las desviaciones de su valor asintótico a altos valores de N deberían corresponder a situaciones estadísticas bajas. El valor de $w(2\pi)$ fluctúa para un tamaño de la interfaz menor de 1000 puntos y se estabiliza sobre ese valor. De aquí en adelante, y para la selección de los datos de la imagen que será usado en el presente trabajo, un umbral del tamaño de la interface tumor-anfitrión de N=1000 puntos será tomado.

Para el caso de la dimensión fractal hicimos lo propio. Cuando usamos la ecuación 4.1 notamos que requiere que se cumplan ciertos criterios para el cálculo de la dimensión fractal. Debido al carácter discreto de la matriz de la imagen habrá ciertos artefactos que aparecerán cuando el radio de los círculos de prueba sea comparable con el tamaño del pixel. Este carácter impone un límite para el cálculo de df . Los radios de los círculos de muestra deben ser apropiadamente seleccionados para evitar algunos artefactos debidos a la discreticidad de la matriz de la imagen. El tamaño del pixel nos da una escala mínima para el muestreo de imagen. Para determinar el tamaño crítico, el método fue aplicado a interfaces simuladas usando círculos de diferentes diámetros, y como consecuencia, diferentes números de puntos de los datos, y se calculó para cada uno el valor de la dimensión fractal usando la ecuación 4.1 y el método del conteo de cajas. En función de eso se evidenció el valor de saturación de la ecuación 4.1. En principio, df debería tener valor de 1 pues estamos hablando de círculos ideales y perfectos, pero por el carácter discreto de

la matriz de imagen llega un valor de radio que produce valores considerablemente diferentes de 1 que resultan ser los artefactos propios de la discretización de la imagen cuando el radio es del valor similar al tamaño del pixel. En la figura 41 se muestra la dependencia de df sobre el tamaño de la interface. El valor de df fluctúa para un tamaño de la interfaz menor de 1000 puntos y se estabiliza sobre ese valor. De aquí en adelante, y para la selección de los datos de la imagen que será usado en el presente trabajo, un umbral del tamaño de la interface tumor-anfitrión de $N=1000$ puntos será tomado. Interesantemente este valor de N coincide con el calculado para el valor de W cuando este se estabiliza. Por lo cual encontramos el valor de saturación tanto para el ancho de la interface como para la dimensión fractal.




Figura 41 Comportamiento de df (dimensión fractal) subtendido por los puntos de la interface de los círculos de muestra.

Para resumir, la selección de datos para el estimado del α_{loc} y para la df envuelve:

- a) El usar círculos de muestra cuyos radios están por encima del límite de escala mínima de la matriz de la imagen (la cual depende de las condiciones de adquisición de la imagen).

- b) Debemos considerar solo los tumores cuya interface presentan un número de puntos por encima de 1000.
- c) Finalmente, para calcular el exponente de rugosidad local, la cual se obtiene a través de un análisis de regresión lineal de la ecuación 4.5, solo consideraremos aquellos resultados que se corresponden con el coeficiente de correlación cuadrática, y que cumplen la condición $r^2 > 0.99$.

CAPÍTULO 5

RESULTADOS Y DISCUSIÓN

El análisis de escalamiento fue aplicado a un total de veinte lesiones tumorales de la piel. Las lesiones de piel fueron clasificadas de acuerdo a sus características en cuatro grupos:

- a. Asimetría, red de pigmentación atípica, pigmentación irregular y proyecciones (8 casos - Lesiones 1, 2, 3, 4, 5, 8, 17, 20.).
- b. Asimetría, Pigmentación Irregular, Color Rosa, Proyección, y Regresión (1 caso - Lesión 7.).
- c. Lesión simétrica, glóbulos marrones y puntos negros de distribución regular (9 casos - Lesiones 6, 10, 11, 12, 13, 14, 15, 16, 18).
- d. Patrón homogéneo y coloración gris azul (1 caso - Lesión 19.).

GRUPO “A” DE LESIONES DE PIEL

Tomemos un caso representativo del **Grupo A** de Lesiones de Piel y veamos cómo fue la segmentación y extracción de borde:




Figura 42 Foto de la lesión 2 como representativa del Grupo A de lesiones de piel, b) Imagen binaria que es la segmentación de la foto a) y c) Borde extraído de la lesión 2 para análisis de escalamiento.

En todos los casos la interfaz del tumor pareció exhibir geometría fractal caracterizada por una dimensión no entera en el rango de 1,02. Pero siendo el cálculo de la dimensión fractal muy sensible de la escala y de la estadística (casos evaluados) no podemos ser concluyentes.




Figura 43 Comportamiento de df (dimensión fractal) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo A.

El exponente local de rugosidad α_{loc} fue calculado y se obtuvo un comportamiento de ley potencial en todos los casos, con pequeñas variaciones, como se muestra en la figura 44 para cada uno de las lesiones correspondientes al Grupo A.




Figura 44 Comportamiento de α_{loc} (exponente de rugosidad) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo A.

GRUPO “B” DE LESIONES DE PIEL

Tomemos ahora un caso representativo del **Grupo B** de Lesiones de Piel y veamos cómo fue la segmentación:




Figura 45 Foto de la lesión 7 como representativa del Grupo B de lesiones de piel, b) Imagen binaria que es la segmentación de la foto a) y c) Borde extraído de la lesión 7 para análisis de escalamiento.

En todos los casos la interfaz del tumor pareció exhibir geometría fractal caracterizada por una dimensión no entera en el rango de 1,03. Como dijimos anteriormente aquí aplica aún más. Este es un solo caso lo cual es una estadística muy pobre para ser concluyentes.




Figura 46 Comportamiento de df (dimensión fractal) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo B.

El exponente local de rugosidad α_{loc} fue calculado y se obtuvo un comportamiento de ley potencial en todos los casos, con pequeñas variaciones, como se muestra en la figura 47 para cada uno de las lesiones correspondientes al Grupo B.




Figura 47 Comportamiento de α_{loc} (exponente de rugosidad) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo B.

GRUPO “C” DE LESIONES DE PIEL

Tomemos ahora un caso representativo del **Grupo C** de Lesiones de Piel y veamos cómo fue la segmentación:




Figura 48 Foto de la lesión 15 como representativa del Grupo C de lesiones de piel, b) Imagen binaria que es la segmentación de la foto a) y c) Borde extraído de la lesión 15 para análisis de escalamiento.

En todos los casos la interfaz del tumor parece exhibir geometría fractal caracterizada por una dimensión no entera en el rango de 1,01. La sensibilidad de variación de la dimensión fractal que depende de los cálculos y de la estadística hace ver que no podemos ser concluyentes al aseverar que los casos exhiben una geometría fractal.




Figura 49 Comportamiento de df (dimensión fractal) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo C.

El exponente local de rugosidad α_{loc} fue calculado y se obtuvo un comportamiento de ley potencial en todos los casos, con pequeñas variaciones dentro de cada grupo, como se muestra en la figura 50 para cada uno de las lesiones correspondientes al Grupo C.




Figura 50 Comportamiento de α_{loc} (exponente de rugosidad) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo C.

GRUPO “D” DE LESIONES DE PIEL

Tomemos ahora un caso representativo del **Grupo D** de Lesiones de Piel y veamos cómo fue la segmentación:




Figura 51 Foto de la lesión 19 como representativa del Grupo C de lesiones de piel, b) Imagen binaria que es la segmentación de la foto a) y c) Borde extraído de la lesión 19 para análisis de escalamiento.

En todos los casos la interfaz del tumor exhibió geometría fractal caracterizada por una dimensión no entera en el rango de 1,01. Siendo el cálculo de la dimensión fractal muy sensible de la escala y de la estadística (casos evaluados) no podemos ser concluyentes.

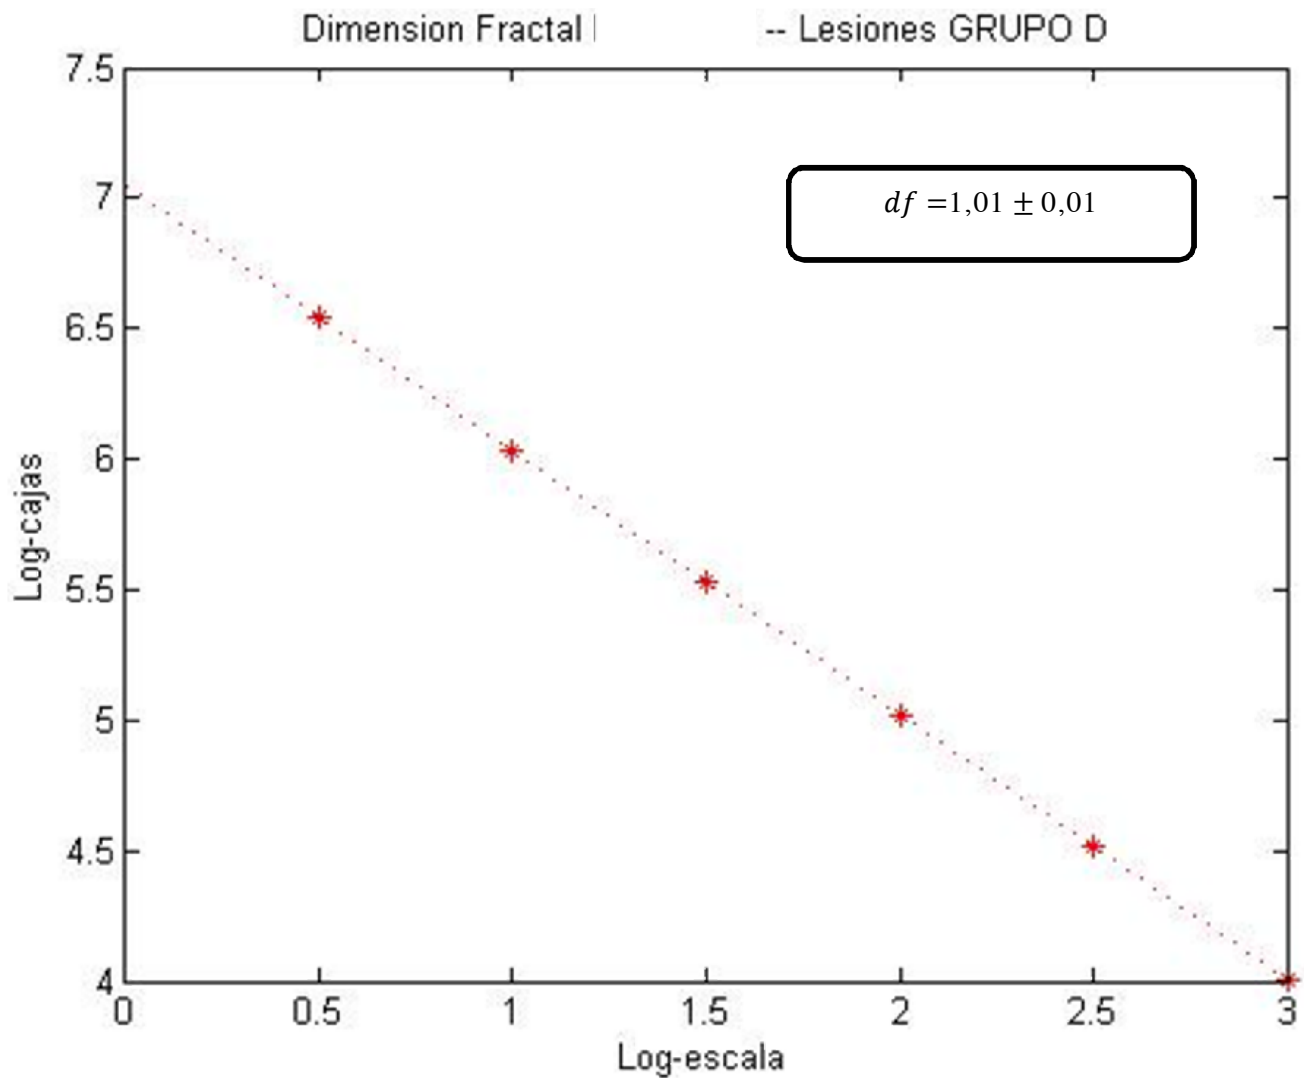


Figura 52 Comportamiento de df (dimensión fractal) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo D.

El exponente local de rugosidad α_{loc} fue calculado y se obtuvo un comportamiento de ley potencial en todos los casos, con pequeñas variaciones, como se muestra en las figura 53 para la lesión correspondiente al Grupo D.

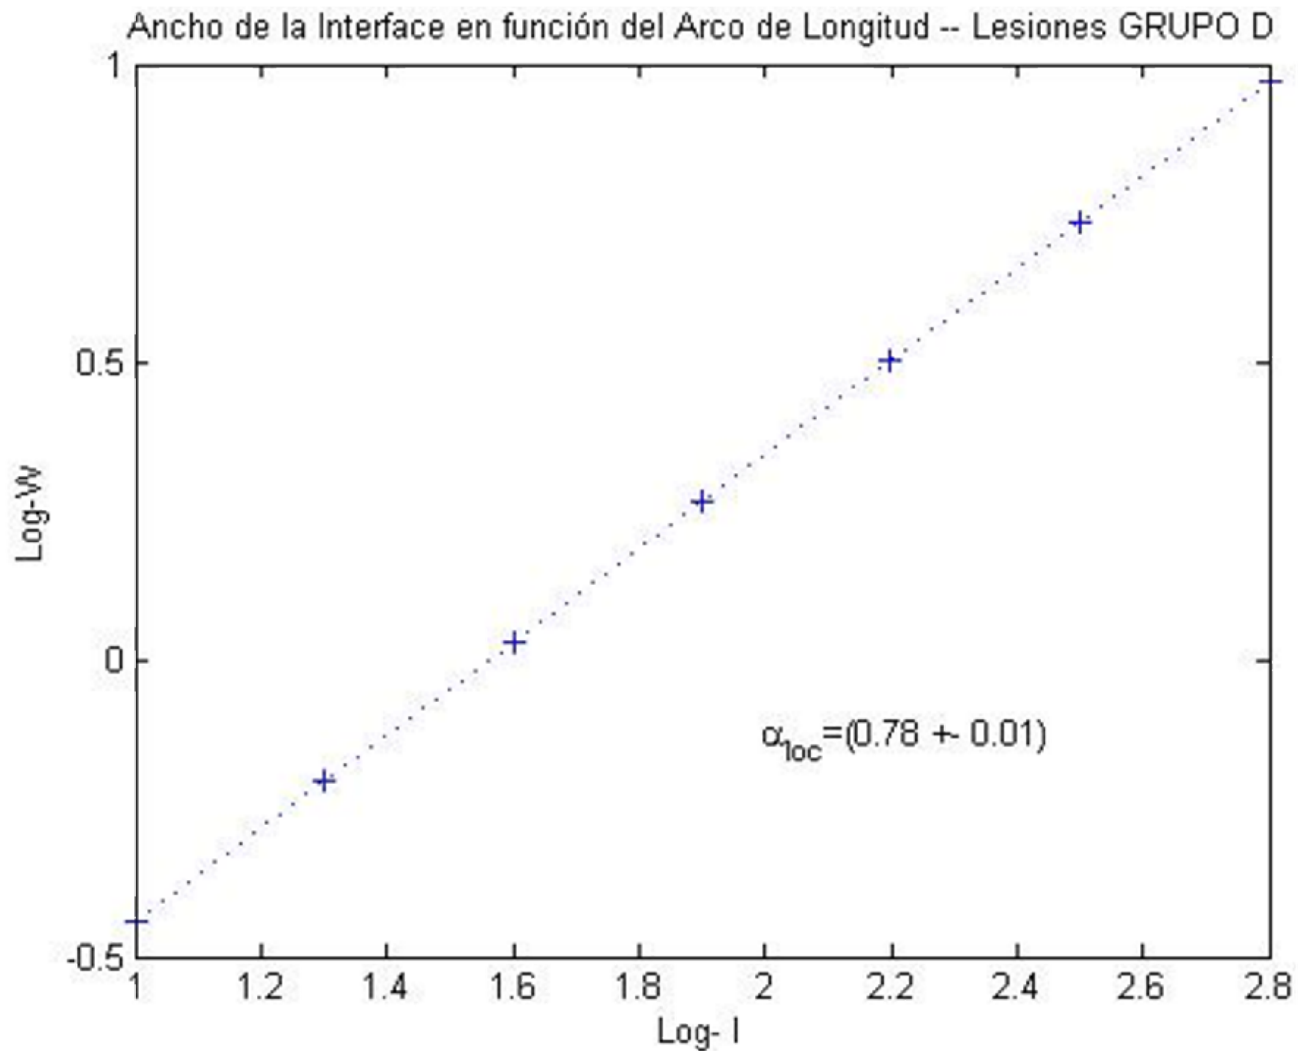


Figura 53 Comportamiento de α_{loc} (exponente de rugosidad) en ley de potencias para las lesiones agrupadas de acuerdo a sus características en el Grupo D.

En la forma como se han agrupado las veinte lesiones que analizamos fue de acuerdo a sus características. Estas características denotan el grado de malignidad de las lesiones. Si las reagrupamos en concordancia con el valor del exponente de rugosidad (α_{loc}), quedaría así desde la menos maligna hasta la más maligna: C, D, A, B. En este orden de malignidad el análisis de las figuras 42-53 revela que el exponente de rugosidad aumenta a medida que el grado de malignidad de la lesión aumenta. También muestra un aparente incremento en la dispersión de este exponente. La tabla 1 resume el resultado de la dimensión fractal df y el exponente de rugosidad local para los diferentes grupos mencionados. Para el grupo más maligno, que corresponde al grupo B tenemos $\alpha_{loc} = 0,85 \pm 0,01$, el cual resulta en armonía con Brú que obtuvo un valor de $\alpha_{loc} = 0,89$ para una metástasis de un melanoma nodal [7]. A mayor valor de este exponente de rugosidad local se entiende que es mayor el carácter invasivo se espera de esta lesión. También para el mismo grupo B tenemos que: $df + \alpha_{loc} = 1,88$. Este resultado difiere del resultado esperado que es de valor 2, es decir, la dimensión euclídea de dos dimensiones y como está establecida en la ecuación general 4.2. Esta misma relación calculada para los otros grupos de lesiones de piel da valores similares, de modo que no pudimos comprobar que esta relación se cumple.

Tabla 1: Lesiones de Piel. Caracterización de la Interface huésped-tumor de las lesiones de piel a través de la dimensión fractal, medida por el método de conteo de cajas, y el exponente de rugosidad local, con sus respectivos errores y coeficientes de correlación cuadrática

TIPO	CASOS	df	α_{loc}	$r^2(df)$	$r^2(\alpha_{loc})$
Grupo A	8	$df = 1,02 \pm 0,02$	$\alpha_{loc} = 0,80 \pm 0,04$	0,999	0,999
Grupo B	1	$df = 1,03 \pm 0,02$	$\alpha_{loc} = 0,85 \pm 0,01$	1,000	1,000
Grupo C	9	$df = 1,01 \pm 0,01$	$\alpha_{loc} = 0,77 \pm 0,05$	0,999	0,999
Grupo D	1	$df = 1,01 \pm 0,01$	$\alpha_{loc} = 0,78 \pm 0,01$	0,999	0,999

CONCLUSIONES

En el presente trabajo llegamos a varias conclusiones producto de todo lo tratado. La importancia de estos estudios radica en que apuntan a proveernos de algún tipo de herramienta diagnóstica con la ventaja de NO SER INVASIVOS. La primera conclusión a la que se llega es que la estadística de casos y la suma sensibilidad a la escala usada se manifiesta en la dimensión fractal y el exponente de rugosidad lo cual no permite ser definitivos en las conclusiones. El algoritmo desarrollado por el Profesor Wuilian Torres resultó ser muy efectivo para eliminar los pelos y para la segmentación de las lesiones. Pero queda una pregunta: ¿Y si se usa otro algoritmo de segmentación, cambiarían los resultados? Seguramente. La misma efectividad presentó el algoritmo que nos da el borde de la lesión basada en una máscara de filtro de 3x3. También concluimos que para aplicar los algoritmos que calculan el ancho de la interfaz y la dimensión fractal existe un límite mínimo de puntos necesarios para que los algoritmos respectivos den valores que no correspondan con artefactos o artificios no propios del cálculo. Se encontró que este número mínimo de puntos debe estar por encima de 1000 puntos de la imagen. En este trabajo las lesiones de piel fueron caracterizadas por análisis por escalamiento, empleando las imágenes suministradas. Estos casos consistieron de diferentes tipos de lesiones que agrupamos en cuatro clases y reordenamos según el grado de malignidad. Posteriormente fueron analizadas tomando en cuenta la morfología de la interfaz de la lesión al calcular sus dimensiones geométricas, es decir, dimensión fractal y el exponente de rugosidad local. El resultado presentado aquí no verificó la relación general entre la dimensión fractal y el exponente de rugosidad local. La más cercana al valor de “2” es el caso de mayor malignidad, el correspondiente al grupo B que da un valor de 1,89 al sumar la dimensión

fractal con el exponente de rugosidad local. Una posible razón de esta diferencia sería debido a que la lesión fue estudiada en un estadio temprano de malignidad. Tenemos la limitante de que son imágenes de un tiempo en particular y no pudimos hacer un análisis de la evolución temporal de la lesión y así calcular nuevamente los parámetros al pasar el tiempo y además calcular los exponentes relacionados con el tiempo. Tenemos también la limitante de no contar con el diagnóstico médico para estos melanomas. Esto nos hubiese podido dar otro parámetro para correlacionar los datos obtenidos con el diagnóstico médico.

RECOMENDACIONES

Para futuros trabajos de análisis de escalamiento de las lesiones de piel recomendamos se incluya una evolución de la lesión en el tiempo con sus respectivos exponentes dependientes del tiempo. Otra recomendación es el probar con otros algoritmos de segmentación y cálculo de borde para comparar y ver si el cálculo de dimensión fractal y análisis de escalamiento se ve afectado por la metodología de segmentación. Para una continuación futura de este trabajo valdría la pena intentar con variar las condiciones de la adquisición de imágenes. Conseguirlas de mejor resolución, variar el tipo de filtro usado, en fin variar el protocolo de adquisición de imágenes para conseguir más información que la que se consigue con el formato JPEG. Otra recomendación sería el tomar una sola lesión y afinar los parámetros para un mismo algoritmo de segmentación y ver si al afinar dichos parámetros se ve afectado el cálculo de la dimensión fractal y del exponente de rugosidad.

También debería incluir una comparación con el diagnóstico médico que sirva para correlacionar la dimensión fractal y los exponentes críticos con el desarrollo de la lesión y su malignidad diagnosticada. También sirva para entender el crecimiento tumoral que arroje luz y ayude a futuro en el tratamiento de esta enfermedad que cada vez más afecta a muchos seres humanos.

APENDICE I

ALGORITMO PARA HALLAR EL BORDE LA LESIÓN A PARTIR DE LA MÁSCARA BINARIA

```

function [SROI, LS]= borde (BWROI)
[n,m] = size(BWROI);
SROI = false(n,m);
cont = 0;
for i=2:n-1
    for j=2:m-1
        if (BWROI(i,j) ~= 0)
            a = BWROI(i-1:i+1,j-1:j+1);
            %       a(1,1) = BWROI(i-1,j-1);
            %       a(1,2) = BWROI(i-1,j);
            %       a(1,3) = BWROI(i-1,j+1);
            %       a(2,1) = BWROI(i,j-1);
            %       a(2,2) = BWROI(i,j);
            %       a(2,3) = BWROI(i,j+1);
            %       a(3,1) = BWROI(i+1,j-1);
            %       a(3,2) = BWROI(i+1,j);
            %       a(3,3) = BWROI(i+1,j+1);
            S = sum(a(:));
            if (S ~= 9)
                cont = cont + 1;
                SROI(i,j) = 1;
                LS(cont) = struct('c',[i j]);
            end
        end
    end
end
end
end

```

APENDICE II

ALGORITMO PARA APLICAR EL SCRIPT ANTERIOR

```
Imagen=imread ('D:\Tesis 2013\2. Segmentación\Imágenes  
Segmentadas\6\6bn.png');
```

```
[SROI, LS]= borde (Imagen);  
figure, imshow(SROI, [])  
save DATA SROI LS
```

APENDICE III

ALGORITMO PARA HALLAR LA DIMENSIÓN FRACTAL

```

function [n,r] = boxcount(c,varargin)
%BOXCOUNT Box-Counting of a D-dimensional array (with D=1,2,3).
% [N, R] = BOXCOUNT(C), where C is a D-dimensional array (with
D=1,2,3),
% counts the number N of D-dimensional boxes of size R needed to cover
% the nonzero elements of C. The box sizes are powers of two, i.e.,
% R = 1, 2, 4 ... 2^P, where P is the smallest integer such that
% MAX(SIZE(C)) <= 2^P. If the sizes of C over each dimension are
smaller
% than 2^P, C is padded with zeros to size 2^P over each dimension
(e.g.,
% a 320-by-200 image is padded to 512-by-512). The output vectors N and
R
% are of size P+1. For a RGB color image (m-by-n-by-3 array), a
summation
% over the 3 RGB planes is done first.
%
% The Box-counting method is useful to determine fractal properties of
a
% 1D segment, a 2D image or a 3D array. If C is a fractal set, with
% fractal dimension DF < D, then N scales as R^(-DF). DF is known as
the
% Minkowski-Bouligand dimension, or Kolmogorov capacity, or Kolmogorov
% dimension, or simply box-counting dimension.
%
% BOXCOUNT(C,'plot') also shows the log-log plot of N as a function of
R
% (if no output argument, this option is selected by default).
%
% BOXCOUNT(C,'slope') also shows the semi-log plot of the local slope
% DF = - dlnN/dlnR as a function of R. If DF is constant in a certain
% range of R, then DF is the fractal dimension of the set C. The
% derivative is computed as a 2nd order finite difference (see
GRADIENT).
%
% The execution time depends on the sizes of C. It is fastest for
powers
% of two over each dimension.
%
% Examples:
%
% % Plots the box-count of a vector containing randomly-distributed
% % 0 and 1. This set is not fractal: one has N = R^-2 at large R,
% % and N = cste at small R.
% c = (rand(1,2048)<0.2);
% boxcount(c);
%
% % Plots the box-count and the fractal dimension of a 2D fractal
set
% of size 512^2 (obtained by RANDCANTOR), with fractal dimension
% DF = 2 + log(P) / log(2) = 1.68 (with P=0.8).
% c = randcantor(0.8, 512, 2);

```

```

%     boxcount(c);
%     figure, boxcount(c, 'slope');
%
%   F. Moisy
%   Revision: 2.10,   Date: 2008/07/09

% History:
% 2006/11/22: v2.00, joined into a single file boxcountn (n=1,2,3).
% 2008/07/09: v2.10, minor improvements

% control input argument
narginchk(1,2);

% check for true color image (m-by-n-by-3 array)
if ndims(c)==3
    if size(c,3)==3 && size(c,1)>=8 && size(c,2)>=8
        c = sum(c,3);
    end
end

warning off
c = logical(squeeze(c));
warning on

dim = ndims(c); % dim is 2 for a vector or a matrix, 3 for a cube
if dim>3
    error('Maximum dimension is 3.');
```

```

end

% transpose the vector to a 1-by-n vector
if length(c)==numel(c)
    dim=1;
    if size(c,1)~=1
        c = c';
    end
end

width = max(size(c)); % largest size of the box
p = log(width)/log(2); % nbre of generations

% remap the array if the sizes are not all equal,
% or if they are not power of two
% (this slows down the computation!)
if p~=round(p) || any(size(c)~=width)
    p = ceil(p);
    width = 2^p;
    switch dim
        case 1
            mz = zeros(1,width);
            mz(1:length(c)) = c;
            c = mz;
        case 2
            mz = zeros(width, width);
            mz(1:size(c,1), 1:size(c,2)) = c;

```

```

        c = mz;
    case 3
        mz = zeros(width, width, width);
        mz(1:size(c,1), 1:size(c,2), 1:size(c,3)) = c;
        c = mz;
    end
end

n=zeros(1,p+1); % pre-allocate the number of box of size r

switch dim

    case 1          %----- 1D boxcount -----%

        n(p+1) = sum(c);
        for g=(p-1):-1:0
            siz = 2^(p-g);
            siz2 = round(siz/2);
            for i=1:siz:(width-siz+1)
                c(i) = ( c(i) || c(i+siz2));
            end
            n(g+1) = sum(c(1:siz:(width-siz+1)));
        end

    case 2          %----- 2D boxcount -----%
%
        n(p+1) = sum(c(:));
        for g=(p-1):-1:0
            siz = 2^(p-g);
            siz2 = round(siz/2);
            for i=1:siz:(width-siz+1)
                for j=1:siz:(width-siz+1)
                    c(i,j) = ( c(i,j) || c(i+siz2,j) || c(i,j+siz2) ||
c(i+siz2,j+siz2) );
                end
            end
            n(g+1) = sum(sum(c(1:siz:(width-siz+1),1:siz:(width-
siz+1))));
        end

    case 3          %----- 3D boxcount -----%
%
        n(p+1) = sum(c(:));
        for g=(p-1):-1:0
            siz = 2^(p-g);
            siz2 = round(siz/2);
            for i=1:siz:(width-siz+1),
                for j=1:siz:(width-siz+1),
                    for k=1:siz:(width-siz+1),
                        c(i,j,k)=( c(i,j,k) || c(i+siz2,j,k) ||
c(i,j+siz2,k) ...
|| c(i+siz2,j+siz2,k) || c(i,j,k+siz2) ||
c(i+siz2,j,k+siz2) ...

```

```

                                || c(i,j+siz2,k+siz2) ||
c(i+siz2,j+siz2,k+siz2));
                                end
                                end
                                end
                                n(g+1) = sum(sum(sum(c(1:siz:(width-siz+1),1:siz:(width-
siz+1),1:siz:(width-siz+1)))));
                                end

end

n = n(end:-1:1);
for i=1:5
    n1(i) = n(i);
end
lncajas = log(n1);
r = 2.^(0:p); % box size (1, 2, 4, 8...)
r1 = 2.^(0:4);
lescala = log(r1);

if any(strncmpi(varargin,'slope',1))
    s=-gradient(log(n))./gradient(log(r));
    semilogx(r, s, 's-');
    ylim([0 dim]);
    xlabel('r, box size'); ylabel('- d ln n / d ln r, local dimension');
    title([num2str(dim) 'D box-count']);
elseif nargin==0 || any(strncmpi(varargin,'plot',1))
    loglog(r,n,'s-');
    xlabel('r, box size'); ylabel('n(r), number of boxes');
    title([num2str(dim) 'D box-count']);
end
if nargin==0
    clear r n
end

figure, plot(lescala,lncajas);
xlabel('Log-escala')
ylabel('Log-cajas')
title('Dimension Fractal linealizada');
```

APENDICE IV

ALGORITMO PARA HALLAR “W” EL ANCHO DE LA DISPERSION DE LA LESIÓN

```

clear all
close all

% Búsqueda de datos de la frontera

folder = uigetdir('M:\2. Segmentación\Imágenes Segmentadas\4', 'Indique
el directorio para los datos de la frontera');
cd(folder)
load DATA

[M N] = size(SROI);
[MM NN] = size(LS);
D(1) = round(M/2);
D(2) = round(N/2);
DD = max(D);
WA = zeros(1,2*DD);
NUA = zeros(1,2*DD);
ARC = zeros(1,2*DD);

sumai = 0;
sumaj = 0;
sumak = 0;
for t=1:NN
    sumai = sumai + LS(t).c(1);
    sumaj = sumaj + LS(t).c(2);
end
i0 = sumai/NN;
j0 = sumaj/NN;
ps = 1;
d0 = 1;

for t=1:NN
%     tt = round(random('unif',1,NN));
    i = LS(t).c(1);
    j = LS(t).c(2);
    r(1) = sqrt(((i-i0)*ps)^2 + ((j-j0)*ps)^2);
    theta(1) = 0;
    for d=2:11
        cont = 1;
        for s=1:NN
            if (s == t)
            else
                ip = LS(s).c(1);
                jp = LS(s).c(2);
                R = sqrt(((ip-i)*ps)^2 + ((jp-j)*ps)^2);
                if (R <= d*d0)
                    cont = cont + 1;
                    r(cont) = sqrt(((ip-i0)*ps)^2 + ((jp-j0)*ps)^2);
                    theta(cont) = 2*acos(((i - i0)*(ip - i0)+(j - j0)*(jp
- j0))/(r(1)*r(cont)));

```

```

        end
    end
end
RR = zeros(1,cont);
TT = zeros(1,cont);
for s=1:cont
    RR(s) = r(s);
    TT(s) = theta(s);
end
sigma = std(RR,1);
WA(d) = WA(d) + sigma^2;
maxTT = max(TT);
meanRR = mean(RR);
ARC(d) = ARC(d) + maxTT*meanRR;
NUA(d) = NUA(d) + 1;
end
end
cont = 0;
for i=2:11
    if (WA(i) > 0) && (NUA(i) > 0) && (ARC(i)>0)
        cont = cont + 1;
        W(cont) = sqrt(WA(i)/NUA(i));
        dd(cont) = ARC(i)/NUA(i);
    end
end
figure, plot(dd,W)
xlabel('dd')
ylabel('W')
title('W versus dd');

save DataW

%hacer un programa de aqui en adelante que permita hacer una regresion
%lineal entre log(W) y log(dd)
F1=log(W);
F2=log(dd);
figure, plot(F2,F1, '+');
xlabel('log dd')
ylabel('log W')
title('logW versus logdd');

```

APENDICE V

ALGORITMO PARA HALLAR EL FACTOR DE CORRELACIÓN DE LAS CURVAS LINEALIZADAS

```
%Calcula el factor de correlacion de las curvas linealizadas
xi=log(dd);
yi=log(W);
a1=sum(xi);
a2=sum(yi);
xiyi=xi.*yi;
a3=sum(xiyi);
xixi=xi.*xi;
a4=sum(xixi);
yiyi=yi.*yi;
a5=sum(yiyi);
a6=mean(xi);
a7=mean(yi);
a8=a2/a7;
sigmaxy=(a3/a8)-(a6*a7);
sigmax=sqrt(a4/a8-a6^2);
sigmay=sqrt(a5/a8-a7^2);
rcorrelacion=sigmaxy/(sigmax*sigmay)
```

APENDICE VI

ALGORITMO PARA HALLAR LA DIMENSIÓN FRACTAL DE LOS CIRCULOS DE PRUEBA PARA EL METODO DE VALIDACIÓN

```

%% PROGRAMA PARA CALCULAR LA DIMENSION FRACTAL DE LOS CIRCULOS DE PRUEBA
clc
clear all
close all

%% Construimos el circulo de radio "r" pixeles
nf = 576;
nc = 768;
[x, y]=meshgrid (1:nc, 1:nf);

r = sqrt((x-nc/2).^2 + (y-nf/2).^2);

p1=input('introduzca el radio del circulo en pixeles: ');

rcirculo = r < p1;
% figure, imshow(rcirculo)
%% Calculamos los puntos del borde
[SROI, LS]= borde (rcirculo);
% figure, imshow(SROI,[])
save DATA SROI LS
%% Organizo los puntos de la lista en una columna
b1 = reshape([LS.c], 2, []);
b2=transpose (b1);
%% Hallo la distancia, la distancia media, y grafico
centro = [nf/2, nc/2];
distanc = sqrt((b2(:,1)-centro(1)).^2 + (b2(:,2)-centro(2)).^2);
p1
rmedio=mean(distanc)
% figure, plot(distanc)
%% Hallamos el ancho de la interface

LS
w=std(distanc)
A1=[p1, rmedio, length(b1), w]
% ww2288= sqrt(mean((distanc287-rmedio).^2))
save A1
save DATAr rmedio w rcirculo

```

BIBLIOGRAFIA

- [1] Mario Mastrodonato, A fractal analysis of skin pigmented lesions using the novel tool of the variogram technique; *Chaos, Solitons and Fractals* 28 (2006) 1119–1135.
- [2] Aribisala, B. and Claridge, E: A Border Irregularity Measure Using a Modified Conditional Entropy Method as a Malignant Melanoma Predictor, *Image Analysis and Recognition, Lecture Notes in Computer Science Volume 3656*, 2005, pp 914-921.
- [3] Zaballos P, Carrera C, Puig S, Malveyh J. Criterios dermatoscópicos para el diagnóstico del melanoma. *Med Cutan Iber Lat Am* 2004; 32(1): 3-17
- [4] Gobierno Federal de México. Abordaje Diagnósticos del Melanoma Maligno. Guía de Práctica Clínica # IMSS547-12. Consejo de Salubridad General.
- [5] Reyes Gamo Villegas. Características Dermatoscópicas de las lesiones melanocíticas en el síndrome de nevus con atipia en diferentes áreas anatómicas y de los melanomas en tronco y extremidades inferiores. Tesis Doctoral. Facultad de Medicina. Universidad Complutense de Madrid. Madrid, 2011 ISBN 978-84-694-5117-2.
- [5] Solomon, Chris & Breckon, Toby (2011). *Representation*. Fundamentals of Digital Image Processing, p.1. Wiley-Blackwell.
- [6] Wodarz, Dominik & Natalia L. Komarova, Dynamics of cancer: mathematical foundations of oncology (University of California, Irvine, USA). World Scientific, 2014.
- [7] Brú, A. y otros. The Universal Dynamics of Tumor Growth, *Biophysical Journal*, Volume 85, 2948-2961, Noviembre 2003.
- [8] F. Torres Hoyo & M. Martín Landrove, 3-D in vivo tumor geometry study by scaling analysis, *Physica A* 391 (2012) 1195-1206.
- [9] Brú, A. y otros. Super-Rough Dynamics on Tumor Growth. *Phys. Rev. Lett.* 81. N° 18 (1998).

- [10] M. Martín-Landrove y D. Pereira / Ciencia Vol. 16, N° 2 (2008) 203-207.
- [11] D. Russel, J. Hanson, E. Ott, Phys. Rev. Lett. 14 (1980) 1175–1178.
- [12] Torres, Wuilian; Segmentación de Imágenes Dermatoscópicas en el Espacio Cielab utilizando filtros morfológicos SML, CIMENIC'S 2014. Puede obtener más información de este algoritmo comunicándose con el Profesor al correo wuiliantor@gmail.com
- [13] R. Sedivy, W. Klin, Wochenschr 108 (1996) 547.
- [14] A. Quintana, M. Martín-Landrove y D. Pereira. Fractal Properties and critical exponents for tumor staging and classification. III International Congress on Computational Bioengineering. Margarita, Venezuela (2007).