

Universidad Central “Marta Abreu” de Las Villas

Facultad de Ingeniería Eléctrica

**Centro de Estudios de Electrónica y Tecnologías de la
Información (CEETI)**



TRABAJO DE DIPLOMA

Aplicaciones Biomédicas de Visión Computacional: Detección Automática de Melanoma

Autor: Jessica Rojas Rosales

Tutor: Dr.C. Alberto Taboada Crispi

Santa Clara

2013

"Año 55 de la Revolución"

Universidad Central “Marta Abreu” de Las Villas

Facultad de Ingeniería Eléctrica

**Centro de Estudios de Electrónica y Tecnologías de la
Información (CEETI)**



TRABAJO DE DIPLOMA

Aplicaciones Biomédicas de Visión Computacional: Detección Automática de Melanoma

Autor: Jessica Rojas Rosales

jessica@uclv.edu.cu

Tutor: Dr.C. Alberto Taboada Crispi

Profesor Titular, Profesor Investigador, CEETI, Facultad de
Ingeniería Eléctrica, ataboada@uclv.edu.cu

Santa Clara

2013

"Año 55 de la Revolución"



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

Firma del Autor

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

Firma del Autor

Firma del Jefe de Departamento
donde se defiende el trabajo

Firma del Responsable de
Información Científico-Técnica

PENSAMIENTO

“Haga todo lo más simple posible, más no de forma simplista (KISS)”

Albert Einstein

DEDICATORIA

A mis padres, por hacerlo posible.

A mi hermana, por el mejor ejemplo.

AGRADECIMIENTOS

A toda mi familia, especialmente a mis padres y a mi hermana, por la preocupación y el apoyo incondicional.

A todos los profesores que en algún momento me impartieron clases, partícipes de mi formación profesional.

A los que compartieron conmigo el mismo curso, la misma aula, los que siguieron y los que se quedaron. A ellos, por caminar junto a mí.

A mis amigos, por la ayuda, la crítica y los buenos consejos. Por escuchar, acompañarme, por brindarme su amistad.

A mi tutor, Dr.C. Alberto Taboada Crispi, de forma muy especial, por su perseverancia, su ayuda y sobre todo su confianza.

En fin, para evitar olvidos, a todos los que de una forma u otra contribuyeron en la realización de esta tesis.

A todos, muchas gracias.

TAREA TÉCNICA

1. Revisión bibliográfica sobre visión computacional.
2. Búsqueda de algoritmos y aplicaciones disponibles sobre visión computacional.
3. Estudio de aplicaciones sobre dispositivos móviles.
4. Implementación de algoritmos de visión computacional para una aplicación biomédica: detección de melanoma.
5. Puesta a punto y evaluación de los algoritmos implementados.

Firma del Autor

Firma del Tutor

RESUMEN

Los dispositivos móviles actuales permiten implementar en ellos aplicaciones biomédicas de visión computacional, como la detección de melanoma, que es un tipo de cáncer de piel muy común. Aquí se adquirieron imágenes JPG de 150 x 150 de lesiones en la piel: 35 de melanoma y 35 de no melanoma. Se les aplicó un filtro de mediana de 7 x 7 al canal verde y se segmentaron con el método de Otsu, para usarlas como referencias en la extracción de rasgos inspirados en el método ABCD (asimetría, bordes, color, dimensiones) y otros de uso clínico. Los 13 rasgos implementados fueron: perímetro p y área A del lunar, p/A , perímetro y área de la caja contenedora, varianza y mediana del lunar, así como las razones de las desviaciones estándar, las medianas y las áreas, de la parte derecha vs. la izquierda y la superior vs. la inferior. Estos rasgos se probaron alimentando una red neuronal de 5 neuronas en la capa oculta y 2 en la de salida, que luego de entrenarse, obtuvo porcentos de exactitud, sensibilidad, especificidad y predictividad (positiva y negativa) similares o superiores a los reportados por otros autores, por encima del 80%. Por la simplicidad de los algoritmos, probados en MATLAB, pudieran implementarse próximamente en dispositivos móviles.

TABLA DE CONTENIDOS

PENSAMIENTO	i
DEDICATORIA	ii
AGRADECIMIENTOS	iii
TAREA TÉCNICA.....	iv
RESUMEN	v
INTRODUCCIÓN	1
CAPÍTULO 1. INTRODUCCIÓN A LA VISIÓN COMPUTACIONAL Y LOS DISPOSITIVOS MÓVILES.....	4
1.1 Visión computacional: conceptos y aplicaciones.....	4
1.2 Etapas en un proceso de visión computacional.....	6
1.2.1 Adquisición de las imágenes.....	7
1.2.2 Modelos de color	8
1.2.3 Preprocesamiento de imágenes.....	8
1.2.4 Segmentación.....	9
1.2.5 Extracción de rasgos	10
1.2.6 Clasificación	11
1.3 Dispositivos móviles como plataformas para aplicaciones sencillas de visión computacional.....	12
1.3.1 Tablets.....	12
1.3.2 Smartphones.....	13
1.4 Posibles aplicaciones biomédicas sencillas de visión computacional.....	14
1.4.1 Aplicaciones reportadas recientemente	14
1.4.2 Detección de melanoma.....	19
1.5 Conclusiones parciales del capítulo	26
CAPÍTULO 2. IMPLEMENTACIÓN DE DETECTOR AUTOMÁTICO DE MELANOMA VIABLE PARA DISPOSITIVOS MÓVILES.....	27
2.1 Bases de datos de imágenes de melanoma.....	27
2.2 Adquisición de nuevas imágenes con dispositivos móviles.....	28
2.3 Preprocesamiento de las imágenes.....	30
2.4 Segmentación de las imágenes.....	30
2.5 Proceso de extracción de rasgos.....	32
2.6 Clasificación.....	37
2.7 Conclusiones parciales del capítulo	39
CAPÍTULO 3. EVALUACIÓN DE LOS ALGORITMOS IMPLEMENTADOS.....	40
3.1 Resultados en la adquisición de imágenes	40

3.2	Selección de parámetros relacionados con preprocesamiento y segmentación	40
3.2.1	Justificación del canal utilizado	41
3.2.2	Evaluación del tamaño de ventana del filtro de mediana	44
3.3	Resultados de la extracción de rasgos	46
3.4	Clasificación.....	49
3.5	Comparación con otros métodos	53
3.6	Conclusiones parciales del capítulo	54
CONCLUSIONES Y RECOMENDACIONES		55
Conclusiones		55
Recomendaciones		56
REFERENCIAS BIBLIOGRÁFICAS		57
ANEXOS		62
Anexo I Base de datos utilizada ((a) lesiones melanocíticas benignas (i1-i35), (b) melanomas malignos (i36-i70))		62
Anexo II Imágenes utilizadas para las pruebas de selección de canal y filtro.....		63
Anexo III Herramienta para reconocimiento de patrones mediante redes neuronales		64

INTRODUCCIÓN

En los últimos años se ha avanzado mucho en las áreas de procesamiento de imágenes y visión computacional. El desarrollo de los dispositivos móviles tales como teléfonos celulares, *laptops*, *netbooks*, *tablets*, que incluyen cámaras fotográficas y de video cada vez de mejores prestaciones a menor costo, ha permitido impulsar una línea de investigación-desarrollo sobre aplicaciones de visión embebida. Dentro de esas aplicaciones se destacan las que tienen que ver con la Ingeniería Biomédica. Esta línea resulta muy atractiva a nivel internacional, pero también a nivel de nuestro país por la importancia que se le concede a la salud humana. Aunque todavía no están muy difundidos, en nuestro país, los dispositivos móviles mencionados anteriormente, sí comienzan a introducirse en determinadas áreas y pudieran ser objeto de generalización en un futuro. Todo esto justifica un acercamiento al tema de las aplicaciones biomédicas de la visión computacional, sobre todo empleando dispositivos móviles.

Situación problemática

Existe una gran diversidad de algoritmos genéricos de visión computacional: detección de bordes, detección de movimiento, reconocimiento y/o seguimiento de objetos en secuencias de video y otras muchas. Por otro lado, están cada vez más asequibles los dispositivos de adquisición de imágenes fijas y en movimiento con cierta capacidad de procesamiento, o sea, cámaras fotográficas y de video, incorporadas a dispositivos digitales inteligentes. Pudieran existir aplicaciones biomédicas que se beneficien con la implementación de algoritmos de visión computacional en dispositivos móviles, pero no se tiene noticias de que se hayan desarrollado en nuestro país. El problema consiste en la necesidad de implementar dichas aplicaciones biomédicas de visión computacional en Cuba.

A continuación se enuncian los objetivos generales y específicos de este trabajo.

Objetivo general:

- Implementar algoritmos simples para la detección automática de melanoma.

Objetivos específicos:

- Recopilar información sobre aplicaciones biomédicas de visión computacional en dispositivos móviles.
- Implementar algoritmo simple para el preprocesamiento de las imágenes de lesiones de la piel.
- Implementar algoritmo simple para la segmentación de lesiones de la piel.
- Implementar algoritmos simples para la extracción de rasgos útiles para la detección automática de melanoma.
- Evaluar la conveniencia y efectividad de los algoritmos implementados para el preprocesamiento, segmentación y extracción de rasgos de lesiones de la piel.
- Probar la efectividad de los rasgos para la clasificación diagnóstica de imágenes sospechosas de melanoma.
- Comentar la viabilidad de implementar estos algoritmos en dispositivos móviles.

Viabilidad

Este trabajo solo persigue un análisis de variantes de implementación en el país de algoritmos simples, de bajo costo computacional, para sistemas de análisis de imágenes y visión sobre dispositivos móviles. No obstante, parece viable esa implementación en un futuro cercano, teniendo en cuenta los avances actuales y por venir en el campo de las TIC en Cuba, que repercute en el desarrollo de equipos médicos para el país, como una prioridad.

Existen imágenes de melanoma disponibles en diversas fuentes de internet. Con respecto a la implementación de los algoritmos, se garantiza la viabilidad al necesitar solo de una computadora con MATLAB instalado. Para el futuro, también se cuenta con teléfono móvil inteligente marca HTC, con cámara de alta resolución, que admite programación en sistema Android. Debe destacarse, para un futuro, la gran disponibilidad, vía internet, de algoritmos y programas para aplicaciones de dispositivos móviles, con sistema Android y otros, que

pudieran acelerar el proceso de implementación final. Por último y no menos importante, se cuenta con relaciones con centros del Sistema Nacional de Salud Cubano que pudieran servir como contraparte.

En el capítulo II se implementa un detector automático de melanoma viable para dispositivos móviles. Se presentan bases de datos de imágenes de melanoma, se describe la forma de adquisición de nuevas imágenes con dispositivos móviles, se explica el preprocesamiento y la segmentación de las imágenes, así como el proceso de clasificación. En el capítulo III se realiza la evaluación de los algoritmos implementados y la presentación de los resultados obtenidos.

En las conclusiones se abordan los principales resultados en concordancia con los objetivos planteados y en las recomendaciones se dan indicaciones para trabajos futuros sobre el tema. La bibliografía aborda las referencias utilizadas en el trabajo. En los anexos se muestran las imágenes de la base de datos utilizada, vistas de la herramienta de clasificación utilizada y los rasgos calculados para la misma.

CAPÍTULO 1. INTRODUCCIÓN A LA VISIÓN COMPUTACIONAL Y LOS DISPOSITIVOS MÓVILES

En este capítulo se realiza una introducción a la visión computacional y a los dispositivos móviles, dándole extrema importancia a conceptos y aplicaciones. Se dan a conocer las etapas en un proceso de visión computacional como son: la adquisición de imágenes, el preprocesamiento de imágenes, la segmentación, la extracción de rasgos y la clasificación. Luego se aborda, con mayor énfasis, los dispositivos móviles como plataformas para aplicaciones sencillas de visión computacional. A continuación son presentadas algunas de las posibles aplicaciones biomédicas de visión computacional usando dispositivos móviles, incluyendo la detección de melanoma, como tema principal del resto de la tesis.

1.1 Visión computacional: conceptos y aplicaciones

La visión computacional es un campo relativamente nuevo y de rápido crecimiento. Los primeros experimentos se llevaron a cabo a finales de 1950, y muchos de los conceptos esenciales se han desarrollado durante los últimos años. Con este rápido crecimiento, las ideas fundamentales han surgido en áreas tan dispares como la inteligencia artificial, la psicología, la computación gráfica y el procesamiento de imágenes [1].

El sueño de los autómatas inteligentes se remonta a la antigüedad; su primera articulación importante en el contexto de equipos digitales fue de Turing hacia 1950. Desde entonces, este sueño se ha llevado a cabo principalmente por los trabajadores en el campo de la inteligencia artificial, cuyo objetivo es dotar a los ordenadores con capacidades de procesamiento de información comparables a los de los organismos biológicos. Desde el

principio, uno de los objetivos de la inteligencia artificial ha sido dotar a las máquinas con la capacidad de lidiar con entradas sensoriales.

La visión computacional es la construcción de explícitas descripciones significativas de objetos físicos a partir de imágenes. La comprensión de imágenes es muy diferente del procesamiento de imágenes, que estudia las transformaciones de imagen a imagen, construcción de la descripción no explícita. Las descripciones son un requisito previo para el reconocimiento y la manipulación, y pensando en los objetos [1].

A continuación se mencionan algunos ejemplos en los que se puede apreciar el campo de aplicaciones de la Visión Artificial [2]:

- Fotogrametría: persigue realizar mediciones del espacio 3D a partir de fotografías tomadas de él, por lo que es posible medir superficies, construcciones, objetos, etc. Así mismo se puede llevar a cabo una topología de un terreno.
- Rectificación métrica: mediante esta técnica es posible hacer correcciones de perspectiva y correcciones de distorsión del lente.
- Reconstrucción 3D: a partir de las vistas, mediante la técnica de triangulación, es posible obtener un modelo 3D del objeto proyectado en las vistas.
- *Matching y tracking*: por medio de estos, es posible encontrar la correspondencia entre puntos de varias imágenes. Los puntos correspondientes son aquellos que representan una proyección del mismo punto físico en el espacio 3D.
- Computación gráfica: si se tiene un modelo de la formación de la imagen $f: 3D \rightarrow 2D$, es posible entonces simular gráficamente las vistas bidimensionales que se obtendrían de un objeto tridimensional. Las aplicaciones de realidad virtual emplean esta teoría.
- Estimación de movimiento: mediante una cámara que toma imágenes de un objeto en movimiento es posible estimar el movimiento del objeto a partir de los puntos de correspondencia en la secuencia de imágenes.

Es obvio que la visión artificial tiene varias aplicaciones menos ambiciosas que la construcción de robots autónomos. Estas aplicaciones pasan por la automatización de una línea de ensamblaje, la inspección de circuitos para detectar defectos, teledetección

para construir mapas de regiones no fácilmente accesibles, comunicación mediante gestos con el ordenador y ayudas a los discapacitados mediante perros guías robots, etc. Entre los sectores donde más se están utilizando actualmente la tecnología de visión artificial se encuentran las industrias: auxiliar del automóvil, farmacéutica, embotellado y embalaje, etiquetado, textil, papel, metalúrgica, semiconductores, cerámica, madera, equipos electrónicos, etc. [3].

En los últimos años las empresas muestran cada vez un mayor interés por los sistemas de visión artificial. Por un lado, existe una creciente necesidad para incrementar la calidad de los productos producidos. Por otro lado, el costo de los sistemas de visión computacional se está reduciendo a precios muy interesantes. Además, las empresas están identificando nuevas aplicaciones/productos en campos como el reciclaje, la biomédica y la robótica [4], [5].

1.2 Etapas en un proceso de visión computacional

La visión artificial lleva asociada una enorme cantidad de conceptos relacionados con *hardware*, *software* y también con desarrollos teóricos [6].

El primer paso en el proceso, es adquirir la imagen digital. Una vez que la imagen digitalizada ha sido obtenida, el siguiente paso consiste en el preprocesamiento de dicha imagen, con el objetivo de mejorar la imagen de forma que el objetivo final tenga mayores posibilidades de éxito. El siguiente paso es la segmentación. Su objetivo es dividir la imagen en las partes que la constituyen o los objetos que la forman. En general la segmentación autónoma es uno de los problemas más difíciles en el procesamiento de la imagen. Por una parte, una buena segmentación facilitará mucho la solución del problema; por otra, la segmentación errónea conducirá al fallo. La salida del proceso de segmentación es una imagen de datos que, o bien contienen la frontera de la región o los puntos de ella misma. Es necesario convertir estos datos a una forma que sea apropiada para el ordenador. La primera decisión es saber si se va a usar la representación por frontera o región completa. La representación por la frontera es apropiada cuando el objetivo se centra en las características de la forma externa como esquinas o concavidades y convexidades. La representación por regiones es apropiada cuando la

atención se centra en propiedades internas como la textura o el esqueleto. Sin embargo, en muchas aplicaciones ambas representaciones coexisten.

La elección de una representación es sólo una parte de la transformación de los datos de entrada. Es necesario especificar un método que extraiga los datos de interés. La parametrización, que recibe también el nombre de selección de rasgos se dedica a extraer rasgos que producen alguna información cuantitativa de interés o rasgos que son básicos para diferenciar una clase de objetos de otra.

En último lugar se encuentran el reconocimiento y la interpretación. El reconocimiento es el proceso que asigna una etiqueta a un objeto basada en la información que proporcionan los descriptores (clasificación). La interpretación lleva a asignar significado al conjunto de objetos reconocidos [3].

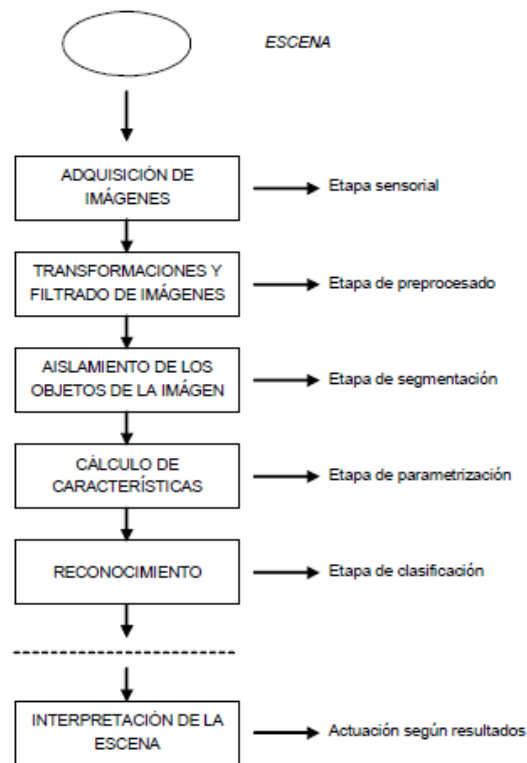


Figura 1. 1. Diagrama en bloques de las etapas de un sistema de visión computacional.

1.2.1 Adquisición de las imágenes

La primera etapa, dentro de un proceso de visión computacional es la etapa de adquisición. En este primer paso, se trata de conseguir que la imagen sea lo más

adecuada posible para que se pueda continuar con las siguientes etapas. Una correcta adquisición de la imagen supone un paso muy importante para que el proceso de reconocimiento tenga éxito. Dentro de esta etapa existen múltiples factores que atañen directamente al proceso de captura de la imagen, formados fundamentalmente por: **el sistema hardware de visión artificial** (cámara, óptica, tarjeta de adquisición de imagen, ordenador y software) y **el entorno y posicionamiento de los elementos** (la iluminación, el fondo, posición correcta de la cámara y ruido eléctrico-óptico externo) [3].

1.2.2 Modelos de color

El propósito de un modelo de color (denominados también espacios de color o sistemas de color) es facilitar la especificación del color en algunos estándares. Esta es la especificación de las coordenadas y un subespacio dentro del sistema donde cada color es representado por un punto.

Dentro de los modelos de color más empleados se encuentran:

- RGB (rojo, verde y azul por sus siglas en inglés) presentes en las cámaras de videos a color y en monitores a color.
- CMY (cian, magenta, amarillo por sus siglas en inglés) y CMYK (cian, magenta, amarillo y negro por sus siglas en inglés) presentes en las impresoras a color.
- HSI (tinte, saturación e intensidad por sus siglas en inglés) que presenta la ventaja de separar los parámetros de color de la luminancia en la imagen [7].

Aunque existen otros modelos, solo se documentan estos por ser los más empleados en la actualidad.

1.2.3 Preprocesamiento de imágenes

Cuando se adquiere una imagen mediante cualquier sistema de captura, por lo general esta no es directamente utilizable por el sistema de visión. La aparición de variaciones en intensidad debidas al ruido, por deficiencias en la iluminación, o la obtención de imágenes de bajo contraste, hace necesario un preprocesamiento de la imagen con el objetivo fundamental de corregir estos problemas, además de aplicar aquellas transformaciones a la

imagen que acentúen las características que se deseen extraer de las mismas, de manera que se facilite las operaciones de las etapas posteriores. A este campo pertenecen las técnicas de transformaciones geométricas, las basadas en el histograma, el filtrado espacial y el filtrado frecuencial. Aunque existen líneas de investigación abiertas, no es el campo más activo en ese sentido, y las técnicas existentes son bastante útiles para la mayoría de las aplicaciones [8].

Algunas de las técnicas más habituales son:

1. Conversión de los niveles de gris: su objetivo es la mejora de la calidad de la imagen.
2. Transformaciones geométricas: los objetivos de ésta son la corrección de la perspectiva y la reconstrucción tridimensional de los objetos de la escena.
3. Transformación del histograma: las transformaciones del histograma pueden facilitar la segmentación de objetos de la imagen, aunque habitualmente sólo sirve para modificar el contraste de la imagen y el rango dinámico de los niveles de gris.
4. Filtrado espacial y frecuencial: dado que pueden suponer una importante modificación de la imagen original, generalmente sólo se consideran filtrados aquellas operaciones realizadas en el dominio espacial o frecuencial que suponen transformaciones pequeñas de la imagen original [9].

1.2.4 Segmentación

Cuando ya se dispone de la imagen capturada y filtrada, es necesario aislar o separar los objetos de interés de la escena. Se pretende por tanto dividir una imagen en diferentes regiones, o dicho de otra forma, detectar automáticamente los bordes entre los elementos o regiones. Las operaciones de segmentación de una escena dependen de la propia escena y de la información que se busque dentro de la imagen. Por ejemplo, en fotografía aérea se utiliza para separar regiones pobladas, agrícolas, bosques y aguas. En imágenes médicas, se usa para aislar zonas enfermas de los órganos, o para detectar y contar microorganismos en microscopía. Industrialmente, se usa como primer paso para la medición de piezas, para determinar la correcta disposición del etiquetado de los envases (aislar el envase, aislar la

etiqueta, determinar si la relación entre estos dos objetos es correcta), para la medición de irregularidades en superficies homogéneas, para la detección de cambios de texturas en las que el sistema ha de determinar si es un defecto o no lo es [10].

Las técnicas básicas de segmentación se pueden dividir en tres grupos [11]:

1. Aplicación de umbrales de niveles de gris.
2. Agrupación por rasgos comunes.
3. Extracción de bordes.

1.2.5 Extracción de rasgos

Con los objetos a estudiar ya definidos, es necesario extraer una serie de medidas que los caractericen adecuadamente, en forma de vector de características.

Como norma general, para la elección de características se intenta que:

1. Sean discriminantes, es decir, tengan valores numéricos diferentes para clases diferentes.
2. Sean fiables, es decir, tengan valores parecidos dentro de una misma clase.
3. Que no estén correlacionadas, es decir, obtener la misma información con el mínimo número de características.
4. Se calculen en un tiempo aceptable, de manera que sean utilizables en problemas de tiempo real.

Dado que las características relevantes son a menudo desconocidas *a priori*, habitualmente se introducen muchas características candidatas para intentar representar mejor las clases, aun cuando muchas de ellas puedan ser parcial o completamente redundantes o irrelevantes. No obstante, existen técnicas para mejorar las prestaciones del conjunto de características escogido inicialmente. Éstas están íntimamente ligadas al reconocimiento de formas en la etapa de diseño del clasificador.

1.2.6 Clasificación

Normalmente, la visión artificial se utiliza para tomar decisiones a partir de la información proporcionada por el sistema de adquisición de imágenes y las transformaciones y operaciones realizadas con ellas. La información extraída se puede considerar como un vector que recoge las características o rasgos diferenciadores de la imagen analizada. En el caso de que se trate de una aplicación de medición, este vector recoge todas aquellas medidas que se deseaban obtener. En aplicaciones de inspección, y sobre todo, en aplicaciones de clasificación, este vector es el conjunto de datos con los que ha de trabajar un reconocedor o clasificador encargado de extraer las conclusiones posibles a partir del vector de entrada. Para el diseño del clasificador es necesaria una etapa de selección de características y una etapa de aprendizaje o entrenamiento. Generalmente, se usa el propio clasificador como evaluador del conjunto de características en prueba dado que el método que proporciona la mayor fiabilidad, aunque sea el más costoso temporalmente y de menor generalidad o capacidad de aplicación del clasificador a otros problemas. Respecto a los métodos clásicos de búsqueda secuencial, actualmente uno de los campos de investigación abiertos es el uso de algoritmos genéticos para la selección en paralelo de características.

En el reconocimiento de formas aplicado a la visión artificial, se utilizan técnicas de reconocimiento geométrico de formas, como el aprendizaje supervisado (se conoce la clase a la que pertenece cada vector) en condiciones estadísticas o algoritmos de clasificación no supervisados o *clustering* y, además, las redes neuronales, siendo estas últimas especialmente interesantes por su capacidad de aprendizaje adaptativo. Existen numerosos algoritmos para cada una de estas técnicas y se investiga ampliamente el desarrollo de nuevos algoritmos e implementaciones *hardware* de éstos. El problema fundamental de estas técnicas, es que cada una de ellas suele ser la más adecuada para las características de un tipo específico de problema no conocidas *a priori*, lo que dificulta la selección de la técnica con la que se desea abordar inicialmente el problema.

1.3 Dispositivos móviles como plataformas para aplicaciones sencillas de visión computacional

En la actualidad, los dispositivos móviles se han convertido en una útil herramienta con la que el usuario disfruta de una amplia variedad de funcionalidades. Más allá de las aplicaciones básicas y llamadas telefónicas, estos pequeños terminales ofrecen una serie de funciones al usuario, tan complejas y provechosas, que los hacen indispensables en la sociedad. El uso extendido de estos aparatos ha provocado no sólo la necesidad de crear nuevas aplicaciones para ellos, sino el hecho también de migrar y adaptar a dichos dispositivos programas ya existentes para ordenador. Android es el sistema operativo de Google para dispositivos móviles. Es una plataforma que ofrece una infinidad de funcionalidades, un importante entorno de desarrollo y un innovador soporte tecnológico. La visión artificial es un campo de la inteligencia artificial que está en auge en los últimos años, y cada día hay más estudios y desarrollos, investigando sus múltiples beneficios para la humanidad, incluyendo implementaciones en dispositivos móviles. Por medio del reconocimiento de patrones y procesamiento de imágenes (entre otras muchas técnicas), se consiguen objetivos como la detección, localización y reconocimiento de objetos en imágenes o la evaluación de resultados, que al ser incorporados a dispositivos móviles, se incrementa su beneficio.

1.3.1 Tablets

El apelativo *tablet PC* se remonta a máquinas con un diseño similar al de un ordenador portátil clásico, pero en pequeño formato y con una pantalla táctil, normalmente abatible y/o giratoria, pensada en un principio para aplicaciones de escritura y dibujo con la ayuda de un lápiz óptico [12].

Estos *tablets* renuncian a muchas piezas clásicas del ordenador portátil, quedándose sólo con la pantalla y cobrando el formato de una pequeña pizarra electrónica. Gracias a los avances en tecnologías táctiles que llevamos años viendo en la telefonía móvil, los botones y otros controles físicos son sustituidos ahora por una pantalla sobre la que el usuario aplica sus propios dedos. El tamaño habitual de esta pantalla es similar al que encontramos en los *netbooks* o miniportátiles de bajo costo.

En cualquier caso, las fronteras que determinan si un producto es o no un *tablet* no son todavía estrictas. Y dichas fronteras no parece que vayan a estar marcadas tanto por lo físico como por las posibilidades del equipo: conexión inalámbrica a Internet, navegación web a golpe de dedo, reproducción de música y vídeo [13].

1.3.2 Smartphones

A lo largo de estos años, los dispositivos de los muchos fabricantes han estado evolucionando e introduciendo nuevas funcionalidades, haciendo que la mayoría de características que se conocen hoy en día, en estándares de mercado que determinan lo que hoy en día conocemos como *smartphone* o teléfono inteligente [14].

Se les llama *smartphone* a los dispositivos que, a partir de la funcionalidad de un teléfono móvil, han evolucionado hasta estar más cercanos, en la actualidad, de un ordenador personal portátil. Es normal hoy en día que esta clase de teléfonos dispongan de agenda, GPS, reproductor de vídeos y música, muchas opciones de conectividad y un número muy grande de funcionalidades que hasta hace unos años eran inimaginables para estos dispositivos [14].

En la figura 1.1 se observan algunos de los diferentes *smartphones* existentes en el mercado, se puede ver la diversidad de diseños y cada uno tiene funcionalidades únicas.



Figura 1. 2. Ejemplos de *smartphones*.

En el 2008 se da a conocer Android, una plataforma de código abierto hecha solo para *smartphones*, la cual se basó en Linux, con una modificación de su *kernel*. Ésta plataforma se transformó en emblema del consorcio Open Handset Alliance, hecho y fomentado por Google en el año 2007 y además “está compuesto por varios fabricantes, desarrolladores y operadores (Intel, HTC, Dell, ARM, Motorola, entre otros) con el propósito de desarrollar estándares abiertos para dispositivos móviles” [14].

1.4 Posibles aplicaciones biomédicas sencillas de visión computacional

Nuevas ideas de diversas aplicaciones y herramientas *online* impactan debido al trato más personalizado al paciente y la mayor implicación de la medicina preventiva. Son, por lo tanto, ideas de negocio que tiene como fin mejorar la salud general y alargar la esperanza de vida de los usuarios [15].

Aunque estas técnicas podrían sonar como ciencia ficción, provocando escepticismo, los promedios de uso y las observaciones personales señalan que estos programas son notablemente precisos [16].

1.4.1 Aplicaciones reportadas recientemente

Massivehealth.com es tanto una plataforma *online* como una aplicación para *iPhone* que evalúa y controla la salud del usuario. Se basa en la idea de que la salud de una persona es un proceso continuado en el tiempo que difícilmente puede ser evaluado por un doctor en una sola visita. Habitualmente las visitas se espacian mucho, se producen cuando estamos enfermos y para curar la enfermedad, y duran muy pocos minutos. El doctor no puede conocer los hábitos del usuario y valorar si estos son más o menos dañinos para su salud.

Por el contrario, usando la interface de *Massivehealth.com*, el médico puede evaluar si el usuario está ganando sobrepeso, consumiendo demasiado azúcar o incrementando los niveles de colesterol. Mediante una aplicación descargable para *iPhone* se pueden recoger datos medibles de su salud y presentar dichos datos en estadísticas visibles para que el médico pueda tomar acciones concretas [15].

Otro ejemplo de las aplicaciones vistas en el mercado es la *Vital Signs Camera* (Figura 1.3) es una aplicación desarrollada por *Philips* que permite determinar el ritmo cardíaco y la

frecuencia respiratoria de las personas, utilizando la cámara del *iPad2* como único hardware. Esta aplicación tiene la particularidad de que puede medir los signos vitales fácil y discretamente. Esta tecnología se basa en el conocimiento de que los latidos del corazón ocasionan pequeños cambios en el color del rostro de una persona, y que el ritmo respiratorio se puede observar a través de los movimientos verticales que hace el pecho cuando se aspira y exhala aire. Estos cambios suelen no ser muy visibles ante el ojo humano, pero el software de la *Vital Signs Camera* hace que la cámara del *iPad2* detecte las “micro-ruborizaciones” faciales para medir el ritmo del corazón. Del mismo modo, la aplicación permite que el sensor de una *tablet* releve los movimientos hacia arriba y abajo que hace el pecho al respirar, con lo que se puede determinar la frecuencia respiratoria del usuario [17].



Figura 1. 3. Ejemplo de la aplicación de la *Vital Signs Camera* [17].

También aparece, para aplicaciones semejantes, la llamada *Azumio's Instant Heart Rate* (Figura 1.4.) que transforma el dispositivo móvil en un monitor de los latidos del corazón rápido y preciso. Puede ser utilizado para optimizar la forma de hacer deporte y de monitorear el esfuerzo, o simplemente para hacer un seguimiento de la frecuencia cardiaca.

Lo único que se tiene que hacer para ello es colocar el dedo índice sobre la cámara del dispositivo y esperar un par de segundos para que se muestre el resultado mediante un gráfico en tiempo real. De esta forma se puede controlar que el pulso no esté nunca fuera de unos límites aceptables [18].



Figura 1. 4. Instant Heart Rate - Pro v2.0.4 [19].

Un grupo de la investigación que trabaja bajo *Aydogan Ozcan* en la UCLA, ha creado un accesorio para teléfono celular (Figura 1.5.) que puede calcular la concentración de *Escherichia Coli* en una muestra líquida. El dispositivo trabaja semejante a un microscopio de fluorescencia, bombeando la muestra en una serie de tubos pequeños tratados con anticuerpos de *E. coli*, luego mide la excitación de puntos cuánticos (fragmentos pequeños de semiconductores) localizados alrededor de los anticuerpos con la cámara del teléfono y una lente adicional. Debido a esta excitación, se puede calcular la concentración de *E. coli* en la muestra. El método fue probado con éxito en una solución especialmente preparada y en un vaso de leche [20].



Figura 1. 5. Teléfono celular con accesorio para calcular la concentración de *E. coli* [20].

Existen anomalías oculares diversas como la miopía, hipermetropía y el astigmatismo. Estas son diagnosticadas y medidas normalmente siguiendo dos procedimientos: la prueba de refracción con un foróptero o una prueba con un instrumento de alta precisión denominado aberrómetro, que define los posibles fallos de la retina usando luz láser. Un equipo de investigadores del Instituto Tecnológico de Massachusetts (MIT), en Estados Unidos, ha desarrollado un sistema llamado NETRA (*Near-Eye Tool for Refractive Assessment*) permitiendo mediciones de una exactitud similar a las realizadas por los aberrómetros, solo que a diferencia de éstos, para utilizarlo se necesita un pequeño accesorio plástico (Figura 1.6.) que se acopla al teléfono móvil [21]. La aplicación funciona mostrando dos líneas que representan dos puntos focales de la retina y utilizando los botones del dispositivo, el usuario debe alinearlas. Después de que el usuario logra ver las líneas alineadas, el programa da un resultado [22].



Figura 1. 6. Prototipo de NETRA. Fuente: MIT [21].

BreathalEyes es otra aplicación de *Apple iOS* para disminuir los riesgos del abuso del alcohol [16]. Este es un detector de alcoholemia para el popular *smartphone*. *BreathalEyes* funciona detectando el nistagmo, que es un movimiento involuntario e incontrolable de los ojos para detectar un posible consumo de alcohol o drogas en los conductores. Como modo de funcionamiento de esta aplicación, basta con situar a la persona frente a la cámara, a una distancia tal que su ojo quede encuadrado en un marco de color verde, haciéndole mantener la mirada hacia un lado durante unos 10 segundos con el ojo bien abierto y sin mover la cabeza (Figura 1.7.). En ese momento la aplicación lee el nistagmo horizontal de la persona enfocada, donde las sacudidas del ojo pueden llegar a tomar una inclinación de 45° respecto de la vertical de la persona. Al leer los datos, la aplicación calcula la tasa de alcoholemia entre unos valores de 0,4 y 1,7 g/l de sangre con un margen de error de un $\pm 0,02\%$ [23].

El *BreathalEyes* le recuerda al usuario que el alcohol es incompatible con la conducción y da la oportunidad de obtener una estimación más o menos real de la tasa de alcohol en sangre. [23].




Figura 1. 7. Forma de aplicación del *BreathalEyes* [23].

También se encuentra como ejemplo la *dbees.com*. Esta es una aplicación específicamente desarrollada para las personas que sufren de diabetes. La aplicación ofrece información y herramientas para ayudar a los diabéticos a lidiar con el día a día utilizando su teléfono. Se trata de una enfermedad con múltiples diferencias en función de la persona, de forma que la aplicación se presenta de manera totalmente flexible para que se adapte a las necesidades de cada uno. Tras insertar los parámetros solicitados, el usuario/paciente será capaz de planificar sus actividades de acuerdo con su esquema diario. Además, los datos se registran en una cuenta *online*, que además se mostrarán con gráficos [18].

En cuanto a las anomalías de la piel, los *smartphones* cuentan con una aplicación de una compañía rumana llamada *Skin Scan*, que analiza y monitorea la progresión de lunares potenciales de melanoma, midiendo su tamaño, forma y color y realizando un seguimiento a su crecimiento con el paso del tiempo. Sobre este tipo de aplicaciones se abunda en la siguiente sección.

1.4.2 Detección de melanoma

El melanoma maligno es hoy día uno de los cánceres principales entre la población de piel blanca alrededor del mundo. Estos crecen en los melanocitos, los cuales son las células responsables de la pigmentación (Figura 1.2).




Figura 1. 8. Vista de una zona de la piel afectada con melanoma.

La única forma de diagnosticar el melanoma es mediante la extracción de tejido y su revisión en busca de células cancerosas. El médico extirpa toda la piel que se ve anormal o solo una parte. En general, este procedimiento se lleva solo unos cuantos minutos. La muestra será enviada a un laboratorio y un patólogo observará el tejido al microscopio para determinar si el melanoma está presente [24]. Sin embargo, debido a la alta incidencia de melanoma maligno, los investigadores se preocupan cada vez más por el diagnóstico automatizado de lesiones de piel. En muchas publicaciones se escriben crónicas como esfuerzos esporádicos en dirección del reconocimiento automatizado de melanoma, mediante el procesamiento de imágenes [25].

1.4.2.1. Introducción al melanoma

El aumento en la incidencia fue primero notada en los Estados Unidos en 1930, donde 1 de cada 100 000 personas por año padecía de cáncer de piel. Esta tasa se incrementó en la mitad de los años ochenta a 6 de 100 000 y a 13 de 100 000 en 1991. Los números son también comparables para las tasas de incidencia observadas en Europa. En 1995, en Austria, la incidencia de melanoma fue aproximadamente 12 de 100 000, lo cual reflejó un incremento de 51,8 % en los diez años previos, y la incidencia de melanoma muestra todavía una tendencia creciente.

Por otra parte las investigaciones han demostrado que la cura del cáncer de piel es casi del 100 %, si es reconocido lo suficientemente temprano y tratado quirúrgicamente. Mientras que la tasa de mortalidad causada por melanomas en los inicios de los años sesenta fue aproximadamente del 70 %, ahora, una tasa de supervivencia de 70 % es lograda, lo cual es principalmente el resultado del reconocimiento temprano [25].

1.4.2.2. Métodos de detección de melanoma y limitaciones

En la práctica clínica existen una serie de métodos aceptados para el reconocimiento de melanoma y otras lesiones de la piel. Sin embargo, todos presentan limitaciones y su empleo resulta muy subjetivo, al depender de la experiencia de los especialistas.

Regla ABCD de dermatoscopia y TDS

La Regla ABCD de Dermatoscopia (método Stolz) aborda cuantitativamente la cuestión de si la lesión melanocítica seleccionada es benigna, sospechosa o maligna. Los criterios se definen por el análisis multivariante y se relacionan con la regla clínica ABCD para el diagnóstico de lesiones pigmentadas de la piel (*Pigmented Skin Lesions*, PSL) (A =asimetría, B = bordes, C = color, y D = dimensiones) [26].

Un sistema de puntuación fue desarrollado utilizando estos criterios: calcula la puntuación total de dermatoscopia (*Total Dermoscopy Score*, TDS) mediante una ecuación lineal. Con el TDS, es posible la clasificación de las lesiones con respecto a su potencial maligno. Se ha escrito que los operadores relativamente inexpertos pueden evaluar con mayor exactitud las lesiones melanocíticas utilizando este método, aunque eso no coincide con la experiencia evaluada por la autora de este trabajo.

Asimetría (A):

Para la evaluación de la asimetría, la lesión es bisecada por dos ejes perpendiculares posicionados para producir la más baja puntuación de asimetría posible. Es importante destacar que, es aconsejable incorporar también el color y la asimetría estructural en este parámetro ELM (*epiluminescence microscopy*) porque las lesiones más equívocas tienen un contorno simétrico. Por lo tanto, la asimetría debe ser calculada de acuerdo con la distribución de los colores y de las estructuras a ambos lados de cada eje, y no basarla

únicamente en el contorno, como en la regla ABCD clínica (es decir, durante la evaluación a simple vista) [27].

Bordes (B):

El énfasis se pone en los bordes que interrumpen bruscamente en la periferia. La lesión es visualmente dividida en 8 segmentos en forma de tarta, y luego se cuenta el número de segmentos en los cuales hay un corte abrupto presente en los márgenes del patrón pigmentado. La puntuación puede variar de 0-8.

Colores (C):

Se evalúan los diferentes colores de la lesión. Ellos incluyen el rojo, blanco, marrón claro y oscuro, azul-gris y negro. El blanco debe contarse sólo si es más ligero que la piel circundante (zonas blancas) y no debe ser confundida con la hipo-pigmentación comúnmente vista en todo tipo de lesiones melanocíticas. A cada color se le asigna un punto, y el total de puntuación va de 1 a 6.

Componentes de estructurales diferentes (D):

En el método clínico, solo se tiene en cuenta las dimensiones del lunar a estudiar, siendo más propenso de padecer melanoma si su diámetro es superior a 6 mm. Sin embargo, en el método TDS, se examinan los componentes estructurales diferentes. Estos componentes incluyen las redes pigmentadas, vetas ramificadas (redes pigmentadas espesadas y ramificadas en cualquier lugar de la lesión, no sólo en los bordes), áreas homogéneas o sin estructura (color, pero no estructuras como redes pigmentadas, vetas ramificadas, puntos, o glóbulos), puntos, y glóbulos. Para ser contada, las áreas homogéneas o sin estructura deben ser mayores que el 10% de la lesión.

Entonces, finalmente se calcula el TDS como:

$$TDS = [(A \times 1,3) + (B \times 0,1) + (C \times 0,5) + (D \times 0,5)] \quad (1.1)$$

Si $TDS > **$, se considera que hay presencia de melanoma.

Método de puntuación de Menzies

El método de puntuación de Menzies es otro esfuerzo por simplificar el sistema ELM (*epiluminescence microscopy*) de análisis de patrones. Esta clasificación identifica dos aspectos negativos y nueve aspectos positivos de uso común en la semiótica de dermatoscopia. Para hacer un diagnóstico de melanoma, deben estar ausentes de la lesión dos aspectos negativos (rasgos negativos), y deben estar presentes uno o dos aspectos positivos (de entre los nueve rasgos positivos).

Rasgos negativos

1. La simetría del patrón está relacionada con la simetría de la lesión melanocítica.
2. Se observa homogeneidad de color (es decir, un solo color).

Rasgos Positivos

1. Un velo azul-blanco aparece como irregular, confluyente, sin estructura, pigmentación azul con una superpuesta de vidrio esmerilado o apariencia turbia.
2. Múltiples puntos marrones aparecen como colecciones focales de múltiples puntos, de color marrón oscuro, que no deben confundirse con los glóbulos de color marrón oscuro que son más grandes y se encuentran comúnmente en los lunares benignos.
3. Puntos negros periféricos y glóbulos aparecen como puntos negros y / o glóbulos que se encuentran en o cerca de la periferia de una lesión.
4. Se observa transmisión radial.
5. Los pseudópodos pueden ser considerados variaciones del cuarto criterio. Ellos son bulbosa orientada radialmente, extensiones parecidas a dedos de la red pigmentada (PN) en la periferia de una lesión. No deben ser puntuados si se ven regularmente o simétricamente alrededor de la lesión.
6. La despigmentación similar a cicatrices (blanco zona cicatricial) aparece de color blanco o blanco lechoso y representa cicatrices ciertas.
7. Se observan múltiples colores (5-6), incluyendo negro, gris, azul, rojo, marrón oscuro, y marrón. El blanco no se cuenta como un color.

8. Múltiples puntos de color azul o gris aparecen como focos múltiples de pequeños puntos de color azul o gris "como pimienta". Ellos son irregulares en tamaño y forma (no glóbulos) en las áreas de regresión.
9. Una red ampliada muestra una PN localizada, engrosada e irregular.

Lista de Siete Puntos

La Lista de 7 puntos es otra variación del sistema de análisis de patrones cualitativos, pero con un sistema de puntuación. Este método utiliza siete criterios específicos para el melanoma. Este incluye 3 criterios principales (se atribuyen 2 puntos a cada uno de ellos), y 4 criterios menores (se atribuye 1 punto a cada uno de ellos). Este método tiene un menor número de criterios para ser identificados y analizados en comparación con el método de Análisis de Patrones TDS. Una puntuación de 3 o más se asocia con una alta probabilidad de diagnóstico de melanoma en la evaluación de la patología [28].

Sin embargo, aunque la dermatoscopia es un adjunto muy útil en el diagnóstico de melanoma, su aplicación es dependiente de la apariencia de los rasgos dermatoscópicos clásicos y por consiguiente está limitado en el diagnóstico de melanomas nacientes y principalmente melanomas que carezcan de rasgos distintivos [29].

1.4.2.3. Sistemas para detección de melanoma basados en dispositivos móviles

La Organización Mundial de la Salud (OMS) define la *e-Health* como "El empleo de información y tecnologías de comunicación para un mejor control de la salud. Por ejemplo, para el tratamiento de determinados pacientes, fomentar la investigación, crear herramientas para la educación de estudiantes, hacer *screening* en diversas enfermedades, y en fin, para la supervisión de la salud pública" [30].

El uso de los modernos sistemas proporcionados por los actuales *smartphone* puede mejorar la adherencia del paciente a los programas de evaluación y control facilitados por centros que trabajan con *e-Health* y poder así ayudar en la prevención de futuros acontecimientos adversos [30].

La reciente proliferación de herramientas de *e-Health* para detección de melanoma y los recursos digitales que facilitan la revisión de los pacientes fuera del ámbito clínico, pueden ofrecer nuevas estrategias para promover la adhesión y ampliar la proporción y el alcance de las personas que efectúan el autoexamen de piel [31].

Existen aplicaciones móviles cuya finalidad es aumentar el diagnóstico de melanoma temprano dependiente del usuario. Estas aplicaciones móviles son capaces dar un diagnóstico ya que incluyen el uso de algoritmos matemáticos para analizar lesiones de piel, la educación en el autoexamen de piel (*skin self-exam* o SSE) o los criterios para el diagnóstico de melanoma, y el seguimiento de fotografías de lunares y recordatorios programados para realizar SSE [31].

En la Tabla 1.1 se presenta un resumen de algunas de las herramientas que ayudan a mejorar el diagnóstico temprano de melanoma. Estas, en su mayoría, van dirigidas a todo tipo de usuarios.

Tabla 1. 1. Herramientas de *e-Health* para el diagnóstico temprano de melanoma [31]

Dispositivo	Vía de Acceso	Fabricante
<i>Análisis de Algoritmo</i>		
“Internet-based”	dermoscopy.k.hosei.ac.jp	Iyatomi, et al.
SkinMD	Apple App store	Estudiantes de la Univ. of Penn.
Skin Of Mine	Apple App store	Medical Image Mining Laboratories, LLC
SpotMole	Android App store	CristianMunteanu
<i>Melanoma Educacional</i>		
Mollie’s Fund	Apple & Android App Stores	MCS Advertising
Melanoma Watch	Apple App Store	Stroika
ABCDEs of Melanoma	Android App Store	MouhammadAouthmany
MelanomaExposed	melanomaexposed.com	Bristol Myers Squibb
Cancer Council Queensland	cancerqld.org.au	Cancer Council Queensland
My Self Checker	Apple App Store	Channel 4
<i>Aprendizaje interactivo</i>		
eDerm	edermopa.com	West Portal Software Corp.
Melanoma Visual Risk Calculator	Apple App Store	SigveDhondup Holmen MD
Skinsafe	nottingham.ac.uk	University of Nottingham

<i>Seguimiento del lunar</i>		
UMSkinCheck	Apple App store	Univ. of Michigan
Track-A-Mole	Android App Store	Peak Mobile Designs
My MoleChecker	Apple App Store	Channel 4
SkinTagger	Apple App Store	Coriumedic Systems LLC
YourSkinDiary	Apple App Store	Buiss Ultimo

1.5 Conclusiones parciales del capítulo

Las aplicaciones de visión computacional por lo general requieren de etapas de adquisición de las imágenes, preprocesamiento, segmentación, extracción de rasgos y clasificación. Los dispositivos móviles, como *tablets* o *smart phones*, se usan cada vez más para implementar en ellos esas aplicaciones. Por otro lado, estas aplicaciones se han extendido a la ingeniería biomédica y un ejemplo concreto es la detección de melanoma, que es uno de los tipos de cáncer de piel de mayor incidencia y malignidad.

CAPÍTULO 2. IMPLEMENTACIÓN DE DETECTOR AUTOMÁTICO DE MELANOMA VIABLE PARA DISPOSITIVOS MÓVILES

En este capítulo se describe la base de datos de imágenes empleada en la evaluación de los algoritmos implementados, además de comentar sobre la adquisición de nuevas imágenes con dispositivos móviles. Luego se definen los algoritmos a usar para preprocesar y segmentar las imágenes, además de extraer los rasgos relacionados con los métodos clínicos de detección de melanoma. Por último, se comenta sobre la herramienta empleada para probar la viabilidad de la clasificación.

2.1 Bases de datos de imágenes de melanoma

El tipo, tamaño, y *ground truth* de las bases de datos usadas para los estudios de evaluación son un factor crítico por generalizar los resultados. Por consiguiente, se monitorearon los grupos de datos que incluían solamente imágenes obtenidas a través de un dispositivo dermatoscópico, debido a que usa condiciones de iluminación controladas. Como con el equilibrio apropiado de intensidad ligera y ganancia de la cámara, imágenes tomadas con cámaras digitales tienen un bajo nivel de ruido electrónico, mientras el ruido de reflexión especular en el dermatoscopio se elimina aplicando inmersión en aceite.

Diferentes bases de datos privadas (y una base de datos estandarizada) con diferentes tamaños, resolución y formato de la imagen, y recursos, son usadas en diferentes estudios. En total, nueve estudios referidos en la literatura sobre el tema, incluyeron 14 421 imágenes dermatoscópicas. Los tamaños de las bases de datos varían desde 30 hasta 2 430 imágenes. En dos estudios se menciona el uso del *ground truth*, el cual fue basado en el dibujo de los bordes del dermatólogo. El tamaño mínimo de las bases de datos fue de 30 imágenes JPEG

de 24 bits, con resoluciones desde 150 x 150 píxeles hasta 2 556 x 1 600 píxeles. El mayor volumen de datos fue basado en 2 430 imágenes con resolución y formato desconocidos. En total 8 110 imágenes dermatoscópicas se han hecho disponibles al público dentro del sistema IRMA [32], aunque fueron imposibles de conseguir durante el desarrollo de este trabajo.

No obstante, otras fuentes alternativas dentro de internet permitieron conformar una base de datos para evaluar los algoritmos implementados. La base de datos fue conformada por 70 imágenes de formato JPEG y son codificadas en 24 bits, que guardan los tres componentes de color r (rojo), g (verde) y b (azul). Estas imágenes RGB son 150x150x3 píxeles en tamaño, con una resolución espacial de 0,0264 cm/píxel.

2.2 Adquisición de nuevas imágenes con dispositivos móviles

Para completar la base de datos de 70 imágenes (35 de ellas con presencia de melanoma), se usaron las cámaras de dispositivos móviles sencillos, que es como se prevé en el futuro que se realice la adquisición de las imágenes. En estas condiciones deben tomarse en cuenta una serie de detalles como la iluminación, la escala, el centrado y la alineación de la lesión, para garantizar un correcto desempeño de los algoritmos simples implementados.

Iluminación

Un gran desafío para la segmentación es la iluminación no uniforme y no central de las imágenes tomadas. La imagen es más luminosa cerca del centro y más oscura cerca de los bordes, pero desgraciadamente el área de la imagen más fuertemente iluminada, no es necesariamente el centro de la imagen, y no tiene la misma localización de imagen a imagen [33].

La iluminación, a la hora de la adquisición de nuevas imágenes, debe ser homogénea, y de forma que no incidan sombras sobre la imagen resultante. Esto se puede lograr mediante la utilización de luz natural, o luces que se proyecten desde varios ángulos, iluminando la región de interés. Todo esto en caso de que la cámara del dispositivo móvil a utilizar no cuente con LED, sino con flash, que no es recomendable debido a que su luz es muy intensa y existe una cercanía relativa entre la cámara y la piel, obteniendo una imagen casi en blanco, que no aporta información. Sin embargo, en caso de contar con un LED, bastaría

para asegurar una iluminación como la deseada, debido a que se observa a través de la cámara, la forma exacta en que va a quedar la foto después de tomada. Por supuesto, nunca se debe tomar en condiciones de penumbra o carentes de luz, de manera que se vean de forma clara todos los detalles posibles de la lesión en cuestión.

Para probar si la imagen obtenida cumple los requisitos necesarios de iluminación, se realiza una evaluación visual de la foto, si esta tiene buena calidad, se hace una segmentación rápida para evaluar la factibilidad de la misma. En caso de obtener como resultado una mala segmentación, se repite el proceso desde el principio, hasta lograr una foto cuya segmentación sea apropiada para el análisis posterior.

Utilizando estas técnicas, siguiendo las recomendaciones descritas, se puede prescindir de algoritmos para la corrección de la iluminación, disminuyendo el costo computacional.

Escala

Los algoritmos se probaron para imágenes de 150x150x3 píxeles con una resolución espacial de 0,0266 cm/píxel. Estas cifras representan una resolución relativamente baja, a la que cualquier dispositivo móvil puede acceder, aunque no sean los de mayor calidad. Casi todas las cámaras presentan resoluciones estándares como 1600x1200, 800x600, 640x480 y 320x240, que exceden las exigencias de esa resolución mínima de 0,0266 cm/píxel.

Para la adquisición de la imagen se podría utilizar un aditamento que regule la distancia de la cámara a la piel, en forma de prisma recto con base cuadrada de 4 cm x 4 cm. De esta forma, se contaría con una referencia para establecer la resolución espacial o escala.

Centrado y alineación (orientación)

Se sugiere, a la hora de tomar la foto, encuadrar bien la lesión a analizar en el centro de la imagen, aunque luego, con la ayuda de algoritmos del programa que hallan el centroide de la lesión, se logra determinar de forma correcta, de forma que el centro de masa de la lesión quede en el centro de la ventana de análisis.

Consecuentemente, se debe orientar la imagen de forma tal que la lesión quede lo más alineada posible respecto a los ejes vertical y horizontal. Esto se hace para prescindir de algoritmos de rotación de la imagen, que conllevarían al incremento del costo computacional, limitándonos solamente a la traslación con respecto a los ejes X y Y.

2.3 Preprocesamiento de las imágenes

El filtro utilizado en el preprocesamiento para eliminar pelos y ruido, fue el filtro de mediana. Un filtro de mediana, como el nombre sugiere, está basado en la mediana de un grupo de números (asociados a los niveles de grises de los píxeles, en este caso). El filtro de mediana reemplaza el valor de un píxel por la mediana de los píxeles vecinos, incluyendo el valor de dicho píxel. La vecindad puede ser de cualquier tamaño y forma, pero para la eliminación de ruido normalmente se usará un cuadrado. Como siempre, la elección correcta de parámetros es importante, en este caso el tamaño y la forma de la vecindad. Si esta es demasiado grande, incluso el filtro de mediana va a alisar los bordes; una vecindad demasiado pequeña no eliminará suficientemente el ruido. Los objetos que son más pequeños que la vecindad pueden ser completamente eliminados al usar un filtro de mediana.

Aquí se usa el filtrado de mediana para acondicionar las imágenes antes de la detección de bordes, pero con una vecindad suficientemente grande para alisar artefactos como el pelo en la vecindad de la lesión. En MATLAB, podemos implementar el filtro de mediana de 7x7 con las siguientes instrucciones:

```
m=7; n=7;  
I = medfilt2(Io(:,:,2), [m n]);
```

2.4 Segmentación de las imágenes

Mientras las imágenes *true color* y en escala de grises tienen valores de píxeles de un cierto rango (dependiendo de la clase de datos), una imagen binaria consta de píxeles con valor 0 o 1. Cuando una imagen binaria está hecha de una imagen en escala de grises, un valor de umbral es determinado. Todos los píxeles con valor por debajo del umbral se pondrán en 0, mientras que el resto se pondrá en 1. Se puede decidir el valor del umbral atendiendo a un número de criterios, dependiendo de qué imagen binaria es necesario representar. Lo más simple es escoger un umbral fijo. Si esto no se puede hacer, como es el caso de segmentar lesiones de la piel, entonces debe ser usada una selección automática de valor del umbral.

Elección del valor umbral

El punto clave es la elección del valor umbral más adecuado. Esto se puede realizar bastante bien de manera manual, pero dado que con las variantes local y dinámica del

método se deben establecer muchos valores umbrales, se necesita un método que permita calcular el mejor valor umbral automáticamente. Hay un gran número de métodos para la elección del valor [34].

Tanto si optamos por calcular el umbral manualmente o mediante un programa, el histograma sigue siendo el elemento más importante. Los máximos locales se corresponden con los objetos de la imagen. En el mejor de los casos el histograma será "bimodal", es decir, en el histograma se podrán reconocer dos picos claramente. Una técnica sencilla, pero también propensa a errores, es elegir como valor umbral la media entre los dos picos del histograma. Otra técnica sencilla es elegir como umbral el valor más bajo entre los dos picos. Con este método seguramente se conseguiría una segmentación algo mejor.

Un método todavía mejor para calcular el valor de umbral automáticamente es el método de Otsu que se ha establecido como estándar. El método de Otsu, llamado así en honor a Nobuyuki Otsu que lo inventó en 1979, utiliza técnicas estadísticas, para resolver el problema. En concreto, se utiliza la varianza, que es una medida de la dispersión de valores, en este caso se trata de la dispersión de los niveles de gris.

El método de Otsu calcula el valor umbral de forma que la dispersión dentro de cada segmento sea lo más pequeña posible, pero al mismo tiempo la dispersión sea lo más alta posible entre segmentos diferentes. Para ello se calcula el cociente entre ambas varianzas y se busca un valor umbral para que este cociente sea el máximo.

Exposición matemática

Como punto de partida tomamos dos segmentos de puntos ($K_0(t)$ y $K_1(t)$), que serán definidos a partir del valor umbral t , que es la variable que buscamos, y los dos segmentos son el resultado deseado en la segmentación.

Sea $p(g)$ la probabilidad de ocurrencia del valor de gris $0 < g < G$ (G es el valor de gris máximo). Entonces la probabilidad de ocurrencia de los píxeles en los dos segmentos es:

K_0 :

$$P_0(t) = \sum_{g=0}^t p(g) \quad (2.1)$$

y K_{10} :

$$P_1(t) = \sum_{g=t+1}^G p(g) = 1 - P_0(t) \quad (2.2)$$

Si tomamos dos segmentos (o sea un solo valor umbral), la suma de estas dos probabilidades dará evidentemente 1. Si \bar{g} es la media aritmética de los valores de gris en toda la imagen, y \bar{g}_0 y \bar{g}_1 los valores medios dentro de cada segmento, entonces se pueden calcular las varianzas dentro de cada segmento como:

$$\sigma_0^2(t) = \sum_{g=0}^t (g - \bar{g}_0)^2 p(g) \quad (2.3)$$

y

$$\sigma_1^2(t) = \sum_{g=t+1}^G (g - \bar{g}_1)^2 p(g) \quad (2.4)$$

La meta es mantener la varianza dentro de cada segmento lo más pequeña posible y conseguir que la varianza entre los dos segmentos sea lo más grande posible. Así se obtiene:

$$Q(t) = \frac{\sigma_{zw}^2(t)}{\sigma_{in}^2(t)} \quad (2.5)$$

La varianza entre los segmentos es:

$$\sigma_{zw}^2(t) = P_0(t) \times (\bar{g}_0 - \bar{g})^2 + P_1(t) \times (\bar{g}_1 - \bar{g})^2 \quad (2.6)$$

La varianza dentro de los segmentos se obtiene de la suma de ambas:

$$\sigma_{in}^2(t) = P_0(t) \times \sigma_0^2(t) + P_1(t) \times \sigma_1^2(t) \quad (2.7)$$

El valor umbral t se elige de manera que el cociente $Q(t)$ sea máximo. Por lo tanto $Q(t)$ es la medida buscada. De esta forma se elige un valor umbral que optimiza los dos segmentos en términos de varianza. En MATLAB se implementa como:

```
level = graythresh(I);  
BW = im2bw(I, level);
```

2.5 Proceso de extracción de rasgos

Para extraer rasgos significativos de las imágenes, basados en los métodos clínicos de detección de melanoma, partimos de la imagen segmentada. Inicialmente se debe preparar la imagen binaria de salida de Otsu, hallando el negativo y rellenando huecos, luego se determinan los bordes, se determina la caja contenedora y el centroide de la lesión, para luego estimar los rasgos en sí, basados en áreas, perímetros, medianas y varianzas.

Negativo y relleno de huecos

Después de la segmentación con Otsu, es necesario realizar el negativo de la imagen resultante, es decir, que los píxeles, antes de color negro se tornen blancos y viceversa. Esto se hace debido a que para la realización del proceso de extracción de rasgos, los algoritmos se basan en los píxeles de valor 1 (blancos) y no en los de valor 0 (negros). Esto no constituye un problema, ya que con simples líneas de código se hace esta conversión, sin mucha complicación del sistema. Es necesario especificar que esto sucede al aplicar este método de segmentación en particular, ya que en Otsu se le da valor 1 a los píxeles que tienen tonalidades de gris más claras, y valor 0 a las más oscuras, y en las imágenes de lesiones de piel, el área de la región de interés correspondiente a la lesión es en su mayoría mucho más oscura que el fondo, correspondiente a la piel circundante; mientras que otros métodos de segmentación se basan en la región de interés. Por lo tanto, de haber utilizado alguno otro no hubiera tenido necesariamente estas mismas características.

El código utilizado es bien sencillo. Se tiene una matriz de unos del mismo tamaño de la imagen, 150×150. Luego se le resta la imagen resultante de la segmentación a esta matriz, donde: uno menos cero es igual a uno (logrando un uno en vez de un cero) y uno menos uno es igual a cero (obteniendo un cero en vez de un uno).

Luego se rellenan los huecos en la imagen para que no influyan en la detección de rasgos.

```
uno=ones(150,150);  
BW=uno-BW;  
BW = imfill(BW, 'holes');
```

Bordes

Los primeros rasgos analizados fueron los referentes a la geometría de los lunares a analizar como el área y el perímetro. Para calcular este último se realizó una traslación de la imagen resultante del negativo en los ejes vertical y horizontal donde BWd es la imagen trasladada a la derecha y BWa es la misma movida hacia abajo (con la diferencia de un solo píxel por ambos ejes). La imagen trasladada hacia la derecha se resta de forma modular de la imagen original. Por tanto, donde inicialmente había un píxel blanco y luego de la traslación de la imagen hay uno negro ($|1 - 0| = 1$), el resultado es un píxel blanco, correspondiente a los píxeles del borde izquierdo de la lesión. Pasa igual cuando se tiene un píxel negro y luego uno blanco ($|0 - 1| = 1$), garantizando los píxeles del borde derecho. Cuando sucede que

no hay diferencia entre los valores de los píxeles de la imagen original y la trasladada, correspondientes al área de la lesión y al fondo de la imagen ($|1 - 1| = 0$ y $|0 - 0| = 0$ respectivamente), el resultado es un píxel negro.

De igual forma se hace para la imagen trasladada en el eje horizontal, es decir, hacia abajo, obteniendo para $|1 - 0| = 1$ el mismo resultado, correspondiente en este caso a los píxeles del borde de arriba de la lesión, y para $|0 - 1| = 1$, los píxeles correspondientes al borde de abajo. Para los otros dos casos, se hace el mismo análisis.

Luego, utilizando imágenes resultantes del proceso anterior, es decir, BWd y BWa sobrescritas se obtiene BWb, relativa a los bordes, realizando una simple suma entre los píxeles correspondientes de las dos imágenes donde $1 + 0 = 1$ y viceversa y $1 + 1 = 2$, que se fuerza a 1, según la última línea de código MATLAB presentada debajo.

```
BWd=BW; BWa=BW;  
BWd(:,1:end-1)=BW(:,2:end);  
BWd=abs(BW-BWd);  
BWa(1:end-1,:)=BW(2:end,:);  
BWa=abs(BW-BWa);  
BWb=BWa+BWd;  
BWb(BWb==2)=1;
```

Para calcular el perímetro, teniendo ya estos datos simplemente se realiza una sumatoria de todos los valores 1 de la imagen BWb obtenida, y el área se calcula de la misma forma pero con relación a la imagen original obtenida del negativo. A continuación se plantea una fórmula relativa a la irregularidad de los bordes donde se divide el perímetro entre el área.

```
% Área y perímetro  
p=sum(BWb(:));  
A=sum(BW(:));  
pa=1000*p/A;
```

Caja contenedora

Luego de hallar estos parámetros, fue necesario realizar un algoritmo para determinar la caja contenedora (*bounding box*) de las lesiones a analizar, con el objetivo de calcular posteriormente otros elementos significativos como su área y perímetro. Para lograr esto, primero fue necesario rellenar los píxeles de las tres primeras y las tres últimas filas y columnas con ceros en la imagen en blanco y negro. Esto se hace para evitar efectos indeseables en los bordes como píxeles blancos aislados en las esquinas que afectan el análisis de la lesión. Luego, el algoritmo busca todos los 1 de la imagen, pero como los

elementos de la matriz son guardados en forma de vector columna, se utiliza la función `ind2sub`, que convierte los índices del vector columna en los correspondientes subíndices (fila, columna) de la matriz. Luego se busca el primer y el último píxel con valor 1, haciendo un barrido por las filas y las columnas para obtener la imagen `bbBW`, relativa al lunar en blanco y negro en la caja contenedora. Esto se logra desechando todo lo que hay encima y debajo de las filas donde está el primer y el último píxel de valor 1 en la imagen y lo que hay antes y después de las columnas donde se encuentran también los píxeles extremos. Luego se utiliza la caja contenedora previamente encontrada para encerrar la lesión original. Para aplicaciones posteriores se utiliza una fórmula para calcular el perímetro y el área de la caja contenedora, basadas en las variables `m` y `n`, correspondientes al ancho y el largo de la caja.

```
% Bounding box
BW(1:3,:)=0; BW(end-2:end,:)=0; % rellena con ceros los extremos de BW
BW(:,1:3)=0; BW(:,end-2:end)=0; % para evitar efectos de borde
un=find(BW);
[i,j]=ind2sub(size(BW),un);
minx=min(i); maxx=max(i);
miny=min(j); maxy=max(j);
bbBW=BW(minx:maxx,miny:maxy); % lunar BW en caja contenedora
bbo=Io(minx:maxx,miny:maxy,:); % lunar original en caja contenedora
[m,n]=size(bbBW);
pbb=2*(m+n); % perímetro de caja contenedora
Abb=m*n; % área de caja contenedora
```

Centroide

Posteriormente se calcula el centroide en la imagen de la caja contenedora en blanco y negro `bbBW`, utilizando el mismo método de antes y la función `ind2sub`, relativa en este caso al tamaño de `bbBW`. Luego, al calcular la media de las posiciones de todos los pares (i,j) , se obtiene satisfactoriamente el resultado deseado.

```
% Centroide bb
un=find(bbBW);
[i,j]=ind2sub(size(bbBW),un);
centrobb=mean([i,j]);
```

A partir de esto, se fuerza el centroide de la lesión al centro de la ventana de análisis de 150×150 .

```
BWcentrada=zeros(150,150);
BWcentrada(75-round(centrobb(1))+1:75-round(centrobb(1))+m,75-
round(centrobb(2))+1:75-round(centrobb(2))+n)=bbBW;
```

Para calcular el centroide del lunar se realiza la misma operación realizada para hallar el centroide de la caja contenedora.

```
% Centroides del lunar
un=find(BW);
[i,j]=ind2sub(size(BW),un);
clunar=mean([i,j]); % centroides del lunar
```

Rasgos definitorios

Basados en los métodos clínicos de detección de melanoma, sobre todo el conocido ABCD, que tiene que ver con la asimetría, irregularidades de los bordes, color y dimensiones del lunar, y tomando como base los cálculos anteriormente descritos, se definió un conjunto de rasgos a estimar.

Los 13 rasgos a estimar son:

- El perímetro, p , de la lesión, ya explicado.
- El área, A , de la lesión, ya explicada.
- La razón p/A , multiplicada por un factor 1000 para facilitar su manejo.
- El perímetro, p_{bb} , de la caja contenedora, ya explicado.
- El área, A_{bb} , de la caja contenedora, ya explicada.
- La varianza de los niveles de gris de la lesión, var_{lun} .
- La mediana de los niveles de gris de la lesión, $mlun$.
- La razón máxima de las desviaciones estándar (máxima entre mínima) de la parte derecha vs. la parte izquierda de la lesión, expresada en porciento, $sdlr$.
- La razón máxima de las desviaciones estándar (máxima entre mínima) de la parte superior vs. la parte inferior de la lesión, expresada en porciento, $sdud$.
- La razón máxima de las medianas (máxima entre mínima) de la parte derecha vs. la parte izquierda de la lesión, expresada en porciento, mlr .
- La razón máxima de las medianas (máxima entre mínima) de la parte superior vs. la parte inferior de la lesión, expresada en porciento, mud .
- La razón máxima de las áreas (máxima entre mínima) de la parte derecha vs. la parte izquierda de la lesión, expresada en porciento, Alr .
- La razón máxima de las áreas (máxima entre mínima) de la parte superior vs. la parte inferior de la lesión, expresada en porciento, Aud .

A continuación se presentan segmentos comentados del código de MATLAB implementado a la medida para poder estimar los rasgos mencionados anteriormente.

```
% mitades superior lunu, inferior lund, izquierda lunl y derecha lunr
lunaru=lunar(1:round(clunar(1)),:,:);
lunard=lunar(round(clunar(1))+1:end,:,:);
lunarl=lunar(:,1:round(clunar(2)),:);
lunarr=lunar(:,round(clunar(2))+1:end,:);
lunu=double(lunaru(lunaru>0));
lund=double(lunard(lunard>0));
```

```

lunl=double(lunar1(lunar1>0));
lunr=double(lunarr(lunarr>0));

varlun=var(lunar);      % varianza del lunar **
mlun=median(lunar);     % mediana del lunar **

sdu=std(lunu);
sdd=std(lund);
sdl=std(lunl);
sdr=std(lunr);
mu=median(lunu);
md=median(lund);
ml=median(lunl);
mr=median(lunr);
sdud=100*(max(sdu,sdd)/min(sdd,sdu)-1); % por ciento de dif de std up-dwn
sdlr=100*(max(sdl,sdr)/min(sdl,sdr)-1); % por ciento de dif std left-right
mud=100*(max(mu,md)/min(mu,md)-1);    % por ciento de dif de medias up-dwn
mlr=100*(max(ml,mr)/min(ml,mr)-1);    % por ciento de dif medias left-right
Au=length(lunu);                      % area de 'mitad' up
Ad=length(lund);
Al=length(lunl);
Ar=length(lunr);
Aud=100*(max(Au,Ad)/min(Au,Ad)-1);    % por ciento de dif de areas up-dwn
Alr=100*(max(Al,Ar)/min(Al,Ar)-1);    % por ciento de dif de areas up-dwn

```

2.6 Clasificación

Como la clasificación en este trabajo no era el objetivo fundamental, se utilizó la herramienta de MATLAB para el reconocimiento de patrones mediante redes neuronales (*Neural Network Pattern Recognition Tool*), que da facilidades gráficas y de uso.

Para acceder a los datos desde esta herramienta se realizó un script en MatLab que guardaba los datos en forma matricial con el nombre de `mela_dataset`, conformando los vectores de entrada `melaTargets` y `melaInputs`. Para `melaTargets`, matriz de dos filas y 70 columnas representativas de las clases a clasificar y la cantidad de imágenes a analizar respectivamente:

- en la primera fila, de la columna 1 hasta la 35 se encuentran las lesiones benignas.
- en la segunda fila, de la columna 36 hasta la 70 se encuentran las lesiones malignas o melanomas.

Lesiones benignas y melanomas son guardadas como unos en las filas 1 y 2, respectivamente. La fila 2, correspondiente a las columnas 1-35 (lesiones benignas) y la fila 1, correspondiente a las columnas 36-70 (melanomas), son rellenadas con ceros (Tabla 2.1).

Tabla 2. 1 Ejemplo de los datos guardados en `melaTargets`.

	1	2	3	...	35	36	37	38	...	70
1	1	1	1	1	1	0	0	0	0	0
2	0	0	0	0	0	1	1	1	1	1

Luego, con una matriz de ceros de 13 filas y 70 columnas (para todos los rasgos de cada una de las imágenes respectivamente) de fondo se corren todas las imágenes (i1-i70), de forma consecutiva mediante la función `num2str` y se van calculando todos los rasgos de cada una de las imágenes, guardándose en la matriz `melaInputs`. Estos son los valores con los que la red neuronal trabaja para para realizar la clasificación.

```
melaTargets=zeros(2,70);
melaTargets(1,1:35)=1;
melaTargets(2,36:70)=1;
melaTargets =zeros(13,70);
for i=1:70,
    fichero=['i',num2str(i),'.jpg'];
    melaInputs(:,i)=melanoma_J(fichero);
end
save mela_dataset melaInputs melaTargets
```

Para acceder a la ventana principal de la *Neural Network Pattern Recognition Tool* (Anexo II (a)), donde se le da al usuario una breve introducción a esta herramienta, se escribe el comando `nprtool` en la ventana de comando de MATLAB. Luego se abre la ventana de selección de datos (Anexo II (b)), desde donde se importa el `mela_dataset` creado que contiene el `melaInputs` y el `melaTargets` (Anexo II (c)). Próximamente aparece la ventana de validación y prueba de datos (Anexo II (d)). En esta aparecen de forma implícita, de las 70 imágenes, valores del 70% (48) para el entrenamiento y 15% para la validación y la prueba (11 y 11 respectivamente). Estos valores también pueden ser ajustados, en nuestro caso lo hicimos a 60% (42), 20% y 20% (14 y 14), respectivamente. Posteriormente, en la ventana donde se presenta el tamaño de la red (Anexo II (e)), se ajusta la cantidad de neuronas escondidas entre 1 y 10000, aunque el valor implícito que da la herramienta es de 20. En este caso, se utilizaron solamente 5 neuronas, con el objetivo de minimizar el costo computacional. Al abrir la ventana de entrenamiento de la red (Anexo II (f)) y comenzar el mismo aparece una ventana donde se dan detalles de la red neuronal obtenida (Anexo II (g)). Al mismo tiempo que van apareciendo en la ventana anterior los valores obtenidos de error cuadrático medio (*Mean Squared Error*) y de porcentaje de error (*Percent Error*) para cada uno de los campos de entrenamiento, validación y prueba. Estos

valores van cambiando según la corrida de entrenamiento. En este estudio, se continuó el entrenamiento para 41 iteraciones. Luego de salvar los datos (Anexo II (h)).

Esta herramienta muestra los resultados (ver sección 3.4) usando tablas de confusión y curvas ROC.

2.7 Conclusiones parciales del capítulo

Existen diversas fuentes de donde se pueden extraer imágenes de lesiones de la piel, incluyendo melanoma, aunque varían mucho sus características: resolución, formato, etc. Para este trabajo se acopiaron imágenes RGB de 150 x 150, en formato JPG, como las que pudieran adquirirse con un móvil de bajas prestaciones: 35 de melanoma y 35 de no melanoma. Se les aplicó un filtro de mediana de 7 x 7 al canal verde para eliminar los pelos y otras irregularidades en la piel y se segmentó aplicando el método de Otsu. Con esa imagen binarizada como referencia, se hallaron 13 rasgos inspirados en el método ABCD (asimetría, bordes, color, dimensiones) y otros de uso clínico. Para la clasificación, se usó una red neuronal con 5 neuronas en la capa oculta y 2 en la de salida, auxiliándonos de la herramienta nprtool de MATLAB.

CAPÍTULO 3. EVALUACIÓN DE LOS ALGORITMOS IMPLEMENTADOS

En este capítulo se hace un análisis de los resultados alcanzados en las diferentes etapas del proceso como la adquisición de imágenes, el preprocesamiento, la segmentación, la extracción de rasgos y la clasificación. También se comparan los resultados obtenidos con otros métodos utilizados y posteriormente se arriba a las conclusiones parciales del capítulo.

3.1 Resultados en la adquisición de imágenes

Se tomaron varias fotos con teléfonos celulares diferentes. De ellas, solo algunas se pudieron segmentar de forma correcta y se eligieron para integrar la base de datos solo las 3 que tuvieron mejor calidad (i4, i5 e i25). Este es un proceso difícil ya que como la aplicación no está implementada en el dispositivo móvil, no se puede saber en el mismo momento si la imagen está correctamente tomada y se puede segmentar, o si hace falta repetirla.

No obstante a esto, las medidas propuestas en la sección 2.2, fueron suficientes para lograr buenas imágenes de donde se puede sacar la información requerida para hacer la clasificación.

3.2 Selección de parámetros relacionados con preprocesamiento y segmentación

Luego de cargar la imagen, como primer paso en el preprocesamiento, fue necesario escoger el filtro de mediana. Para esto, primeramente se escogió el canal RGB que iba a ser utilizado, ya que era necesario ubicarse en un espacio de color para pasar el filtro. El preprocesamiento y la segmentación tienen una relación directa como se verá en este

epígrafe. Todos los efectos del filtro repercuten luego en la segmentación. Es por esta razón que no se trataron como elementos separados, sino que se fueron analizando conjuntamente, es decir, se evaluaron los resultados del uso de los diferentes filtros en la segmentación obtenida de los mismos.

No se contó con el *ground truth* como estándar dorado para evaluar la segmentación, así que se usaron pruebas visuales para evaluar la misma tomando como referencia 10 imágenes representativas (Anexo II).

3.2.1 Justificación del canal utilizado

Aunque siempre se ha expresado que la segmentación basada en la información de color en el espacio vectorial HSI es más intuitiva, frecuentemente la que mejores resultados obtiene es la que usa el vector de color RGB [9]. Para evitar mayor cómputo se decidió utilizar uno solo de los canales que conforman este modelo de color.

Para la selección del canal a utilizar fueron mostradas a los especialistas 10 tiras de imágenes para su evaluación. Cada una de ellas constaba de cinco imágenes: la primera, correspondiente a la original de la lesión, las tres siguientes, representaciones de las imágenes resultantes de la separación de los diferentes canales (rojo, verde y azul respectivamente) y la cuarta, pertenece a la imagen llevada a niveles de grises. Para evitar sesgo en la evaluación de los especialistas, se le presentaron los canales en un orden aleatorio, desconocido por ellos (aunque, naturalmente, se tuvo en cuenta su designación real para decidir cuál es más adecuado). La evaluación consistió en darle una puntuación a cada imagen correspondiente a los diferentes canales y a la de niveles de grises entre 1 y 4, tomando como la imagen con mejor contraste y más detalle el número 1 y a la peor, el 4. La Tabla 3.1 muestra el resultado de esta evaluación donde se señalan en rojo las dos tiras de imágenes donde los tres especialistas coinciden en su criterio (Figuras 3.2 y 3.3, respectivamente).




Figura 3. 1. Tiras de imágenes de la imágenes original 5




Figura 3. 2. Tiras de imágenes de la imágenes original 7

Con los resultados obtenidos, fue calculada la puntuación total para cada canal y para la imagen en niveles de grises, determinándose que el de menor puntuación era el mejor como consenso de los especialistas. Los resultados fueron 100, 52, 71, y 77, para los canales rojo, verde y azul y la imagen en niveles de grises, respectivamente.

Tabla 3. 1. Resultado de la evaluación de los especialistas con respecto al uso de los diferentes canales.

Expertos	1				2				3				Consenso			
	r	g	b	ng	r	g	b	ng	r	g	b	ng	r	g	b	ng
I1	4	2	1	3	4	1	2	3	4	2	1	3	12	5	4	9
I2	4	1	2	3	4	2	1	3	4	2	1	3	12	5	4	9
I3	4	1	2	3	4	2	1	3	4	2	1	3	12	5	4	9
I4	4	1	2	3	4	1	2	3	4	2	1	3	12	4	5	9
I5	4	1	2	3	4	1	2	3	4	1	2	3	12	3	6	9
I6	4	2	1	3	4	1	2	3	4	1	2	3	12	4	5	9
I7	1	3	4	2	1	3	4	2	1	3	4	2	3	9	12	6
I8	2	3	4	1	3	2	4	1	4	1	3	2	9	6	11	4
I9	4	1	2	3	4	2	3	1	4	1	3	2	12	4	8	6
I10	1	3	4	2	2	1	4	3	1	3	4	2	4	7	12	7
Total	32	18	24	26	34	16	25	25	34	18	22	26	100	52	71	77

Se determinó entonces, utilizar el canal verde debido a los resultados obtenidos, pero también se realizó un análisis utilizando histogramas. Para citar un ejemplo, se muestra en la Figura 3.4, los histogramas para la tira de imágenes 5 (Figura 3.2), donde se ve claramente que el canal rojo (A) no puede ser utilizado para la segmentación, ya que su

histograma no es bimodal, es decir, casi no hay ninguna diferencia entre los niveles de grises pertenecientes a la lesión y los pertenecientes al fondo (piel). Para los otros tres casos se ven histogramas bimodales definidos. El histograma del canal verde, presenta mayor lejanía entre los picos, por tanto existe una mayor diferencia entre los tonos de gris de la lesión y los de la piel circundante, logrando un mejor contraste.




Figura 3. 3. Histogramas de la tira de imágenes 5 (Anexo I) correspondientes a los diferentes canales: rojo (A), verde (B) y azul (C) y a la imagen en niveles de grises (D).

Este es un ejemplo ilustrativo extremo, pero puede ser generalizado, ya que en la mayoría de las imágenes de lesiones de piel, hay un gran contenido de rojo debido a que las personas de piel blanca (mayormente afectadas por lesiones que las de piel oscura), tienden a tener la piel de tonalidades rosadas, y muchas de las lesiones tienden a tener tonalidades rojas. También existen casos donde la lesión presenta colores muy oscuros (casi negro) (Figura 3.3) y la piel es rojiza, logrando entonces la imagen del canal rojo mayor contraste

entre las cuatro. No obstante a estos casos, para la mayoría no es así, además es válido señalar y poniendo esta figura como ejemplo, que aún cuando el mejor contraste se ve en el canal rojo, en el verde se definen claramente los bordes, logrando una muy buena segmentación.

3.2.2 Evaluación del tamaño de ventana del filtro de mediana

Al aplicar los filtros a la imagen de determinada lesión, como ya se ha establecido antes, mejoran muchos factores que afectan la segmentación. En la Figura 3.4, se ejemplifica uno de estos casos, donde es necesario eliminar los finos bellos de la piel. A simple vista el de mejor resultado logrando este objetivo es el filtro 7×7 , pero también se nota que la imagen ha perdido el enfoque de la lesión, viéndose un poco más distorsionada que las otras, lo que como es de suponer, también influye en la segmentación. Para saber hasta qué punto esta ha sido afectada, fue necesario hacer pruebas visuales con la segmentación resultante de cada una de las imágenes correspondientes a los tres filtros.

Fue aplicado el mismo método anterior, con las mismas imágenes originales.




Figura 3. 4. Resultados de los filtros de mediana 3×3 , 5×5 y 7×7 respectivamente.

Fue aplicado el mismo método anterior, con las mismas imágenes originales presentadas aleatoriamente para evitar sesgo. En este caso se realizaron las 10 tiras de imágenes correspondientes a los filtros. Cada una de ellas, constaba de cuatro imágenes: la primera, correspondiente a la original de la lesión y las otras tres, representaciones del preprocesamiento utilizado con filtro de mediana 3×3 , 5×5 y 7×7 respectivamente. La evaluación fue dada entre 1 y 3, tomando como la mejor segmentación el número 1 y a la peor el 3. La Tabla 3.1 muestra el resultado de esta evaluación donde se señalan en rojo las tres tiras donde los tres especialistas coinciden (Figura 3.1).




Figura 3. 5. Tiras de imágenes (de la imágenes originales 1, 7 y 8 respectivamente) a las que los tres especialistas dan la misma puntuación

Los resultados en este caso fueron 83, 52 y 45 para los filtros de 3×3 , 5×5 y 7×7 respectivamente. De esta forma, tanto cualitativa como cuantitativamente, se determinó que el filtro 7×7 era el mejor para lograr el objetivo deseado, ya que con su uso se logra un fondo más homogéneo, eliminando pelos, arrugas y manchas o lunares no pertenecientes a la lesión, que son incluidas en la imagen debido a su cercanía con la misma. Esto presenta un compromiso a la hora de realizar la segmentación, ya que, mientras mayor es la ventana del filtro, más difuminada y desenfocada se ve la imagen, no obstante también se logra una buena segmentación después de aplicar un filtro de 7×7 .

Tabla 3. 2. Resultado de la evaluación de los especialistas con respecto al uso de los filtros.

Expertos	1			2			3			Consenso		
	3x3	5x5	7x7	3x3	5x5	7x7	3x3	5x5	7x7	3x3	5x5	7x7
I1	3	2	1	3	2	1	3	2	1	9	6	3
I2	2	1	3	3	1	2	3	2	1	8	4	6

I3	3	2	1	2	3	1	3	2	1	8	7	3
I4	1	2	3	3	1	2	2	3	1	6	6	6
I5	3	2	1	3	2	1	3	1	2	9	5	4
I6	3	1	2	3	2	1	3	1	2	9	4	5
I7	3	2	1	3	2	1	3	2	1	9	6	3
I8	3	2	1	3	2	1	3	2	1	9	6	3
I8	3	2	1	3	1	2	2	1	3	8	4	6
I10	3	1	2	2	1	3	3	2	1	8	4	6
Total	27	17	16	28	17	15	28	18	14	83	52	45

3.3 Resultados de la extracción de rasgos

En la regla ABCD, el método de Menzies y la lista de 7 Puntos, que son los métodos de clasificación de melanoma más reconocidos, aparecen como factor común, de forma directa o indirecta, rasgos distintivos como: la asimetría, la irregularidad de los bordes, homogeneidad del color y dimensiones de la lesión. Inspirados en estos se propusieron nuevos rasgos mediante el cálculo de elementos esenciales y relacionándolos entre ellos.

Basado en esta idea se calculó el perímetro (p) y el área (A) de la lesión, a partir de las imágenes resultantes de la segmentación después del negativo y el relleno de huecos y la imagen donde los bordes son definidos (Figura 3.6), fundamentales en este análisis, y también la división del primero entre el segundo (pa). Mediante esta relación se buscaba una idea de irregularidad en los bordes, con el perímetro directamente proporcional al resultado. De esta forma, un valor grande de pa, podría ser representativo de una lesión con grandes irregularidades.




Figura 3. 6. Imágenes en las cuales se aprecian el área y los bordes de la lesión.

También se hallaron los datos de la caja contenedora del lunar (Figura 3.7) para su área y su perímetro (Abb y pbb, respectivamente). Valores altos son representativos de lunares

grandes, que corren mayor riesgo de ser melanoma. Para el pbb se vieron valores desde 70 hasta 456, con una mediana de 229. Tomando esta como referencia, el 31,4% de las lesiones benignas superaban este valor, mientras que las malignas lo hacían en un 68,6%, lo que denota una diferencia importante a la hora de la clasificación. Como es de suponer para el área ocurre lo mismo, ya que es directamente proporcional al perímetro, y se trata de un rectángulo, o en el más extremo de los casos, de un cuadrado. Estas medidas se corresponden con el tamaño de la lesión, y pudieran asociarse al diámetro en la regla ABCD.

Caja contenedora BW



Figura 3. 7. Imagen de la caja contenedora de la lesión para la imagen BW.

Luego los lunares son divididos por sus respectivos centroides en cuatro partes: mitad superior e inferior y mitad derecha e izquierda (Figura 3.8). A cada una de estas partes se le calcula la desviación estándar correspondiente (sdu , sdd , sdr y sdl , respectivamente). Con el uso de esta medida se relacionan los rasgos distintivos de color y asimetría. Se halló entonces las razones entre las desviaciones estándares por los dos ejes, horizontal y vertical, es decir, la razón entre las desviaciones estándares de las partes superior e inferior ($sdud$) y derecha e izquierda ($sdrl$). Los valores de estos parámetros fueron dados en porciento. Para la $sdud$, con mediana de 4,8%, el 34,3% de las lesiones benignas la superaron. Sin embargo, para el caso de las malignas, fue un 65,7%. Para $sdrl$ los valores fueron parecidos. El valor de la mediana fue de 5,9% y la sobrepasaron, de las benignas, un 40,0% y de las malignas, el 62,9%. Estos eran aproximadamente los resultados esperados ya que mientras mayor sea la desviación estándar mayor probabilidad tendrá el lunar de ser melanoma.




Figura 3. 8. Imagen de la lesión dividida en las cuatro partes.

También se calcularon las medianas de la cuatro partes divididas nombradas mu, md, mr, y ml (arriba, abajo, derecha e izquierda respectivamente). Con ellas, se logró determinar las razones entre la mediana superior e inferior (μ_{ud}) y la de la parte izquierda y derecha (μ_{lr}) para cada una de las imágenes. Para la primera se obtuvo una mediana del 8,0%, superándose en un 40% de lesiones benignas y en un 60% de malignas. Para la segunda se obtuvieron casualmente los mismos resultados relativos a la μ_{ud} , pero en este caso para una mediana de 8,1%. Estos valores de media obtenidos se corresponden también con el criterio de que mientras mayor sea la mediana, entre las dos partes evaluadas, menos simetría tiene el lunar.

Fueron calculadas las cuatro áreas del lunar correspondientes a las cuatro partes (A_u , A_d , A_l , A_r) y fueron relacionadas con la misma idea que en los demás casos, es decir, hallando la razón entre las áreas superior e inferior, expresadas en porciento (A_{ud}) y las áreas de la parte derecha e izquierda (A_{lr}).

El clasificador utilizado basado en redes neuronales le da un factor de peso a cada uno de estos rasgos y los relaciona entre ellos. Es por esta razón que se incluyen los 13 parámetros

hallados como vector de entrada al clasificador, ya que en caso de que uno de ellos no obtenga muy buenos resultados, no se le da tanto peso como a otros que sí lo tienen.

3.4 Clasificación

Para analizar la respuesta de la red en la Figura 3.6, es mostrada la matriz de confusión realizada por la misma herramienta de MATLAB para el reconocimiento de patrones mediante redes neuronales, donde son mostrados varios tipos de errores que ocurrieron para la red final especializada.

Las celdas diagonales resaltadas en verde en cada tabla muestran el número de casos que fueron correctamente clasificados, y las celdas diagonales resaltadas en rojo muestran los casos mal clasificados. La celda azul de cada tabla muestra el porcentaje total de casos correctamente clasificados (en verde) y el porcentaje total de casos mal clasificados (en rojo). Por el 'eje y' se tienen las clases de salida y por el 'eje x' se tienen las clases objetivas (resultado después de la clasificación), tomando a 1 como melanoma y 2 como no melanoma o benigno. Es decir, donde coinciden dos 'unos', aparece el valor relativo a los verdaderos positivos correspondientes a melanoma-melanoma (V_p) y donde coinciden dos 'dos', aparece el valor relativo a los verdaderos negativos correspondientes a benigno-benigno (V_n). El caso 'uno-dos' representa los melanomas clasificados como benignos, representativos de los falsos negativos (F_n) y el caso 'dos-uno' representa los no melanomas clasificados como malignos, representativos de los falsos positivos (F_p).

Los valores pertenecientes a las celdas en gris, presentan los valores expresados en porcentaje de predictividad positiva y predictividad negativa (por la columna y en verde) y de sensibilidad y especificidad obtenidas (por fila y en verde).

Los resultados para las tres bases de datos (entrenamiento, validación, y prueba) muestran un reconocimiento muy bueno, sobre todo en las dos primeras, alcanzando valores por encima del 90%.



Figura 3. 9. Matriz de confusión para el entrenamiento, la validación y prueba y la matriz de confusión final (arriba a la izquierda, arriba a la derecha, abajo a la izquierda y abajo a la derecha respectivamente).

El resultado de la clasificación superó los valores esperados, obteniendo un porcentaje de clasificación correcta de un 91,4% con solo 6 imágenes mal clasificadas, 1 benigna y 5 malignas.

En la Figura 3.7 se muestran las curvas ROC (*Receiver Operating Characteristic*), donde las líneas a color en cada eje representan las curvas ROC para cada una de las cuatro

categorías en esta red. En las curvas ROC se grafican los verdaderos positivos (sensibilidad) contra los falsos positivos ($1 - \text{especificidad}$) según varía el umbral. Una prueba perfecta mostrará los puntos ploteados en la esquina superior izquierda, con un 100% de sensibilidad y un 100% de especificidad. Para este problema, la red se desempeña muy bien, como puede ser observado en la figura.

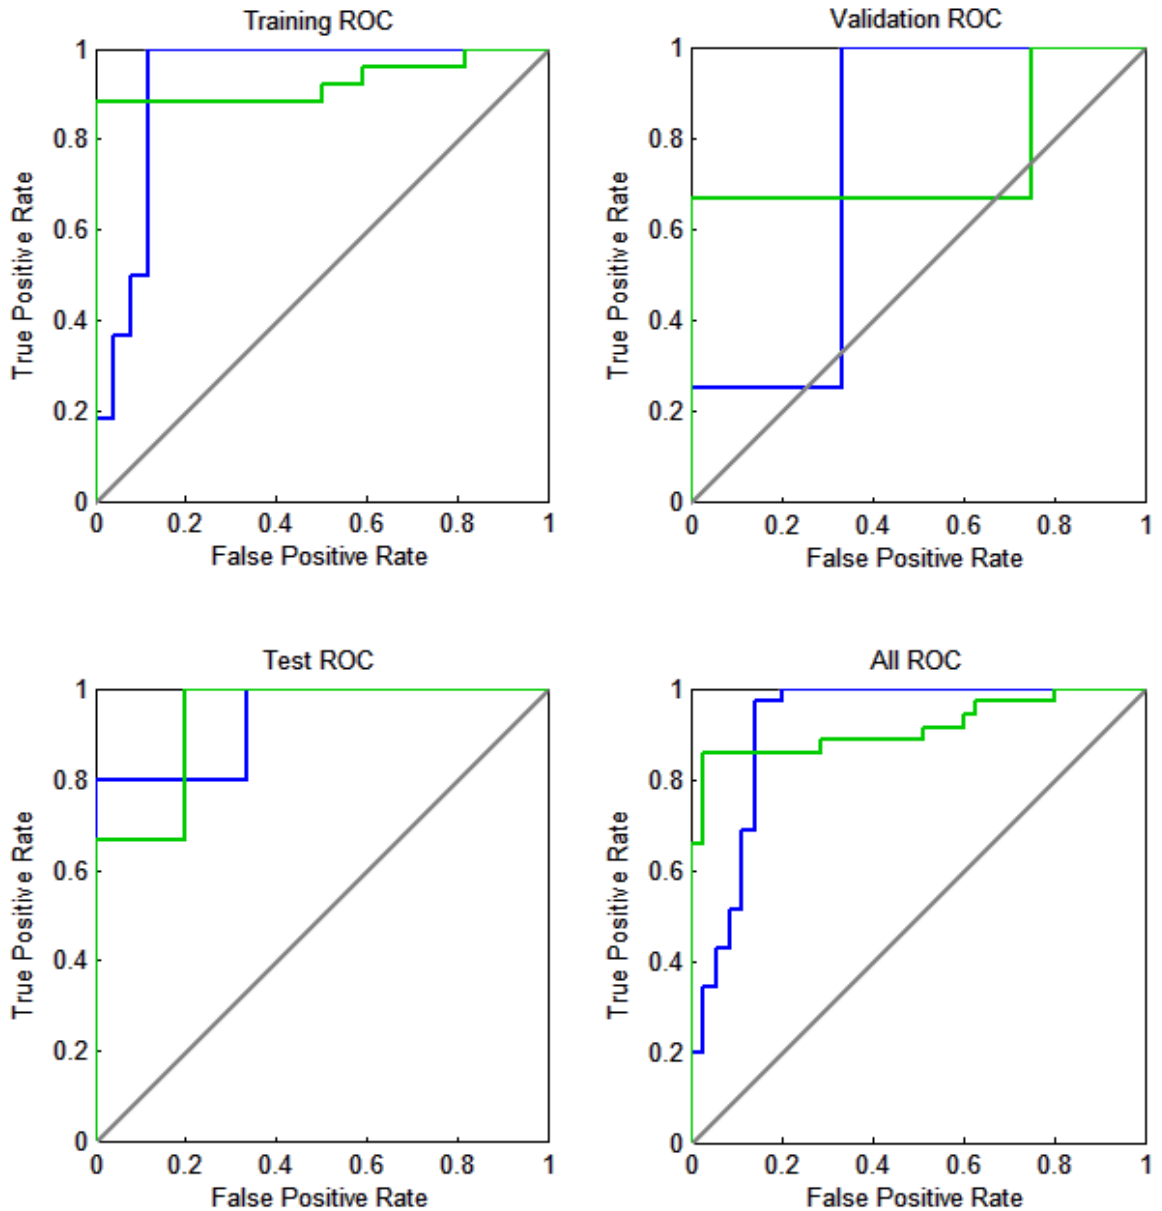


Figura 3. 10. Curvas ROC para el entrenamiento, la validación y prueba y la curva final (arriba a la izquierda, arriba a la derecha, abajo a la izquierda y abajo a la derecha, respectivamente).

Para encontrar el error de validación, la herramienta realiza un ploteo de los errores en el entrenamiento, la validación, y la prueba, como se muestra en la Figura 3.8. Para la corrida de entrenamiento ejemplificada, el mejor desempeño de validación ocurrió en la iteración 42, y la red en esta iteración es retornada.




Figura 3. 11 Resultados del desempeño

El estado de entrenamiento de la red se muestra en la Figura 3.9 donde se hace un análisis del gradiente y de chequeo de validación hasta la iteración 48.




Figura 3. 12. Estado de entrenamiento de la red

3.5 Comparación con otros métodos

Los resultados obtenidos en la clasificación fueron comparados con otros métodos ya reportados en la literatura.

En [26] se utilizan los rasgos distintivos de la regla ABCD para el diagnóstico de melanoma. En esta investigación se presentan tres diagnósticos, melanoma, sospechoso, y lesión de piel no cancerosa. El experimento usa 30 pruebas de imágenes de lesiones dermatoscópicas que son sospechosas de cáncer de piel de melanoma. Basada en el experimento, la exactitud del sistema es del 85 % ya que hay 4 diagnósticos falsos de las 30 pruebas.

En [25] se usaron imágenes a color de lesiones de piel, técnicas de procesamiento de imágenes y clasificador de AdaBoost en 95 imágenes de lunares benignos y 25 imágenes de melanoma maligno obteniendo una clasificación correcta de 86,10%.

Utilizando el programa del autor (melanoprot) se evaluaron las 70 imágenes de la base de datos. En las 35 imágenes de lesiones benignas, se clasificaron 16 como melanomas, y con una (i3), el programa se bloqueaba, así que nunca se obtuvo una clasificación. En las otras 35 correspondientes a las lesiones malignas, tuvieron una mala clasificación 6 imágenes. La comparación de los resultados obtenidos por melanoprot y melanoma_J (algoritmos propios) se muestra en la Tabla 3.3, donde la diferencia es aplastante.

Tabla 3. 3 Comparción de resultados obtenidos por melanoprot y melanoma_J

	Vp	Vn	Fp	Fn	Se (%)	Sp (%)	Pp (%)	Pn (%)	Cc (%)
melanoprot	29	18	6	17	63	75	83,9	51,4	67,1
melanoma_J	34	30	5	1	97,1	85,7	87,2	96,8	91,4

3.6 Conclusiones parciales del capítulo

Los métodos aplicados en el capítulo 2 mostraron su eficacia. Se verificó que el canal verde era el más apropiado para usar como referencia al segmentar y que la ventana de 7 x 7 lograba un buen filtrado de mediana que garantizaba la segmentación de Otsu. Los rasgos fueron extraídos con algoritmos sencillos implementados en MATLAB para la ocasión, pero demostraron ser suficientemente robustos. Por último, se obtuvieron consistentemente valores por encima del 80% (superior a lo reportado por otros autores) de sensibilidad, especificidad, predictividad positiva, predictividad negativa y exactitud.

CONCLUSIONES Y RECOMENDACIONES

Conclusiones

En este trabajo se cumplieron los objetivos trazados, al implementar con éxito algoritmos para la detección automática de melanoma.

Se recopiló información actualizada sobre las aplicaciones biomédicas de visión computacional usando dispositivos móviles, donde aparece la detección de melanoma.

Se demostró la conveniencia de un filtro de mediana de 7×7 sobre el canal verde como un algoritmo apropiado para el preprocesamiento de las imágenes de lesiones de piel.

Se corroboró que el sencillo método de Otsu aplicado sobre el canal verde filtrado (mediana 7×7) es suficiente para segmentar las lesiones de la piel.

Los 13 rasgos sencillos (perímetro p y área A del lunar, p/A , perímetro y área de caja contenedora, varianza y mediana del lunar, razón de desviaciones estándar, de medianas y de áreas, de parte derecha vs. izquierda y superior vs. inferior) implementados inspirados en el método ABCD (asimetría, bordes, color y dimensiones) y otros de uso clínico resultaron útiles para la detección automática de melanoma.

La clasificación diagnóstica de imágenes sospechosas de melanoma es posible con el uso de una red neuronal de 5 neuronas en la capa oculta y 2 en la de salida, alimentada con los 13 rasgos.

Los algoritmos implementados fueron evaluados exitosamente, obteniendo al final porcentajes de exactitud, sensibilidad, especificidad y predictividad (positiva y negativa) superiores a los reportados por otros autores, por encima del 80%.

Por la simplicidad de los algoritmos, pudieran implementarse en dispositivos móviles.

Recomendaciones

A partir de los resultados obtenidos, se sugiere como trabajo futuro, la implementación de los algoritmos en algún dispositivo móvil.

También sería recomendable, el ampliar la base de datos a partir de imágenes tomadas con el propio dispositivo en que serán implementados los algoritmos.

Para estandarizar la adquisición de las imágenes, debe implementarse un dispositivo con una estructura rígida que mantenga la distancia entre el móvil y la piel del sujeto, además de ofrecer una cuadrícula como referencia para el posicionamiento manual de la cámara y para el recorte y centrado automático.

REFERENCIAS BIBLIOGRÁFICAS

- [1] D. Ballard and C. M. Brown, Computer vision, New York: Prentice-Hall, Inc, 1982.
- [2] B. Jahne, P. Geissler and H. Haussecker, Handbook of Computer Vision and Applications, Morgan Kaufmann Publishers Inc., 1999.
- [3] A. González Marcos [et al.] (integrantes del Grupo de Investigación EDMANS), Técnicas y algoritmos básicos de Visión Artificial, La Rioja: Universidad de La Rioja, Servicio de Publicaciones, 2006.
- [4] telekosmu, "Visión Artificial para aplicaciones biomédicas," 16 abril 2013. [Online]. Available: <http://mukom.mondragon.edu/ict/vision-artificial-para-aplicaciones-biomedicas/>. [Accessed 18 junio 2013].
- [5] W. E. L. Grimson and J. L. Mundy, "Computer vision applications," *Communications of the ACM*, vol. 37, pp. 44-51, 1994.
- [6] R. Hartley and A. Zisserman, Multiple view geometry in computer vision, Cambridge Univ Press, 2000.
- [7] J. Wu, P. Zeng and e. al., "A novel color image segmentation method and its application to white blood cell image analysis," in *8th International Conference on Signal Processing*, 2006.

- [8] IACI, "Aspectos de un sistema de Visión Artificial," 2005.
- [9] J. R. Parker, *Algorithms for image processing and computer vision*, Wiley, 2010.
- [10] L. Ping, "A survey on threshold selection of image segmentation," *Image and Graphics*, pp. 86-92, 2004.
- [11] M. D. Levine and S. I. Shaheen, "A modular computer vision system for picture segmentation and interpretation," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, pp. 540-556, 1981.
- [12] M. E. Arcia, "Por qué comprar una tableta," 2011. [Online]. Available: <http://tabletas.about.com/od/Conoce-las-tabletas/a/Por-Qu-E-Comprar-Una-Tableta.htm>. [Accessed 4 junio 2013].
- [13] L. Laó Ramos, "Los tablets, su presente y su futuro," 6 abril 2010. [Online]. [Accessed 17 julio 2012].
- [14] R. D. Osorio and C. A. Ramírez, "Características y parámetros de la seguridad para los smartphones con sistema operativo Android," Pereira, 2011.
- [15] L. Suarez, "Aplicaciones para iPhone y Android que cuidan de tu salud," 17 noviembre 2011. [Online]. Available: <http://www.teinspira.com/aplicaciones-para-iphone-y-android-que-cuidan-de-tu-salud-2/>. [Accessed 2 octubre 2012].
- [16] B. Dipert, "Embedded Vision In Medicine: Let Smartphone Apps Inspire Your Design Decisions," 14 May 2012. [Online]. Available: <http://www.mdtmag.com/blogs/2012/05/embedded-vision-medicine-let-smartphone-apps-inspire-your-design-decisions>. [Accessed 15 May 2012].
- [17] J. Tapiador, "Philips Vital Signs Camera ayuda a medir los signos vitales a través del iPad 2," 21 noviembre 2012. [Online]. Available: <http://pclan-es.blogspot.com/2012/11/philips-vital-signs-camera-ayuda-medir.html>. [Accessed 13

marzo 2013].

- [18] J. Sánchez, "Las diez mejores aplicaciones médicas para Android," 19 noviembre 2012. [Online]. Available: http://www.abcdesevilla.es/mobility/las_mejores_app/android/las-10-mejores-aplicaciones-medicas-para-android/. [Accessed 18 junio 2013].
- [19] Cristian-U, "Instant Heart Rate - Pro [Android]," 11 abril 2011. [Online]. Available: <http://www.nocturnar.com/forum/recursos/525149-instant-heart-rate-pro-android.html>. [Accessed 18 noviembre 2012].
- [20] A. Robertson, feb 2010. [Online]. Available: <http://www.theverge.com/2012/2/23/2818765/cell-phone-e-coli-detection-attachment-ucla>.
- [21] Y. Martínez, "Un sistema diagnostica la falta de vista con el móvil, en tan sólo dos minutos," 30 junio 2010. [Online]. Available: http://www.tendencias21.net/Un-sistema-diagnostica-la-falta-de-vista-con-el-movil-en-tan-solo-dos-minutos_a4619.html. [Accessed 12 junio 2013].
- [22] J. F. Mastromarino, "MIT Netra, Android para optometria," 3 julio 2010. [Online]. Available: <http://androidzone.org/2010/07/mit-netra-android-para-optometria/>. [Accessed 18 octubre 2012].
- [23] J. Camós, "BreathalEyes, o cómo medir la alcoholemia con un iPhone," 9 enero 2012. [Online]. Available: <http://www.motorpasionfuturo.com/ayudas-a-la-conduccion/breathaleyes-o-como-medir-la-alcoholemia-con-un-iphone>. [Accessed 18 junio 2013].
- [24] Instituto Nacional del Cáncer, "Lunares comunes, nevos displásicos y el riesgo de melanoma," 1 noviembre 2011. [Online]. Available: <http://www.cancer.gov/espanol/recursos/hojas-informativas/riesgo-causas/lunares>.

[Accessed 5 junio 2013].

- [25] L. Rosa, "Automated Melanoma Recognition," 23 febrero 2011. [Online]. Available: <http://www.advancedsourcecode.com/melanomarec.asp>. [Accessed 25 noviembre 2012].
- [26] B. Amaliah, C. Fatichah and M. Widyanto, "ABCD Feature Extraction for Melanoma SkinCancer Diagnosis," 2011.
- [27] P. Shetty and V. Turkar, "Melanoma Decision Support System for Dermatologist," Mumbai, 2011.
- [28] I. Stanganelli, "Dermoscopy," Oct 2008. [Online]. [Accessed 2012 nov 2012].
- [29] H. Skvara, L. Teban, M. Fiebiger, M. Binder and H. Kittler, "Limitations of Dermoscopy in the Recognition of Melanoma," *ARCHDERMATOL*, vol. 141, pp. 155-160, feb 2005.
- [30] J. L. Palma Gámiz, "¿Qué es la eHealth?," 11 junio 2013. [Online]. Available: http://www.ediagnostic.es/Blog_de_telemedicina-V4-Que_es_la_eHealth.html. [Accessed 18 junio 2013].
- [31] A. Tyagi, K. Miller and M. Cockburn, "E-Health Tools for targeting and improving melanoma screening: a review," *Journal of Skin Cancer*, p. 8, 2012.
- [32] A.-R. A. Ali and T. M. Deserno, "A Systematic Review of Automated Melanoma Detection in Dermatoscopic Images and its Ground Truth Data," Aachen, Germany, 2012.
- [33] G. GRAMMATIKOPOULOS and e. al., "Automated Malignant Melanoma Detection Using MATLAB," Macedonia, 2006.
- [34] S. Khakabi, P. Wightona and T. K. A. M. S. Leea, "Multi-level feature extraction for skin lesion segmentation in dermoscopic images," *Medical Imaging*, vol. 8315, no.

SPIE, Oct 2012.

- [35] B. Dipert, "E. Coli: Cameraphone-Based Embedded Vision Is Your Fluorescence-Detection Eye," 24 febrero 2012. [Online]. Available: <http://www.embedded-vision.com/news/2012/02/24/e-coli-cameraphone-based-embedded-vision-your-fluorescence-detection-eye>. [Accessed 19 junio 2013].
- [36] Instituto Nacional del Cáncer, "Melanoma," [Online]. Available: <http://www.cancer.gov/espanol/tipos/melanoma>.
- [37] Integrantes del grupo de investigación EDMANS, Técnicas y algoritmos básicos de Visión Artificial, La Rioja, 2006.
- [38] R. J. Schalkoff, Digital image processing and computer vision, New York: Wiley New York, 1989.

ANEXOS

Anexo I Base de datos utilizada ((a) lesiones melanocíticas benignas (i1-i35), (b) melanomas malignos (i36-i70))




(a)

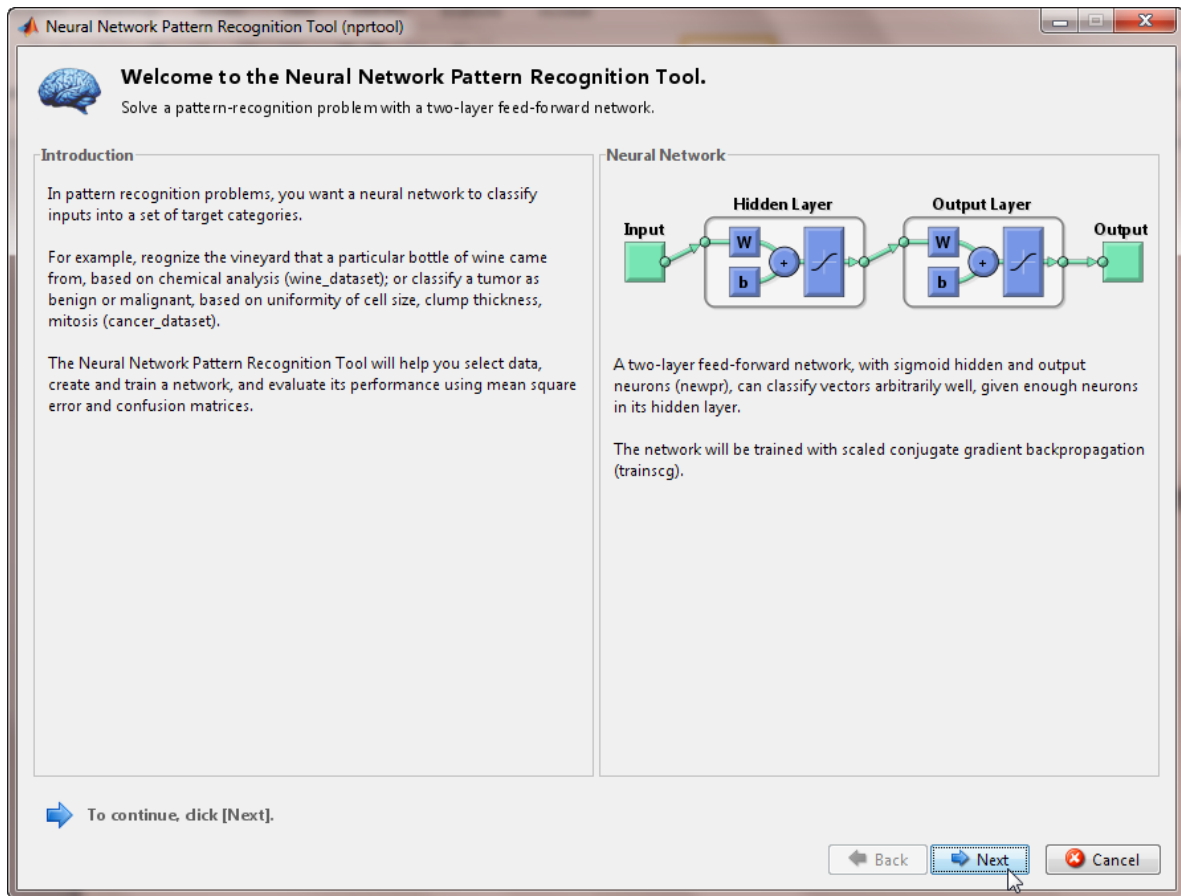


(b)

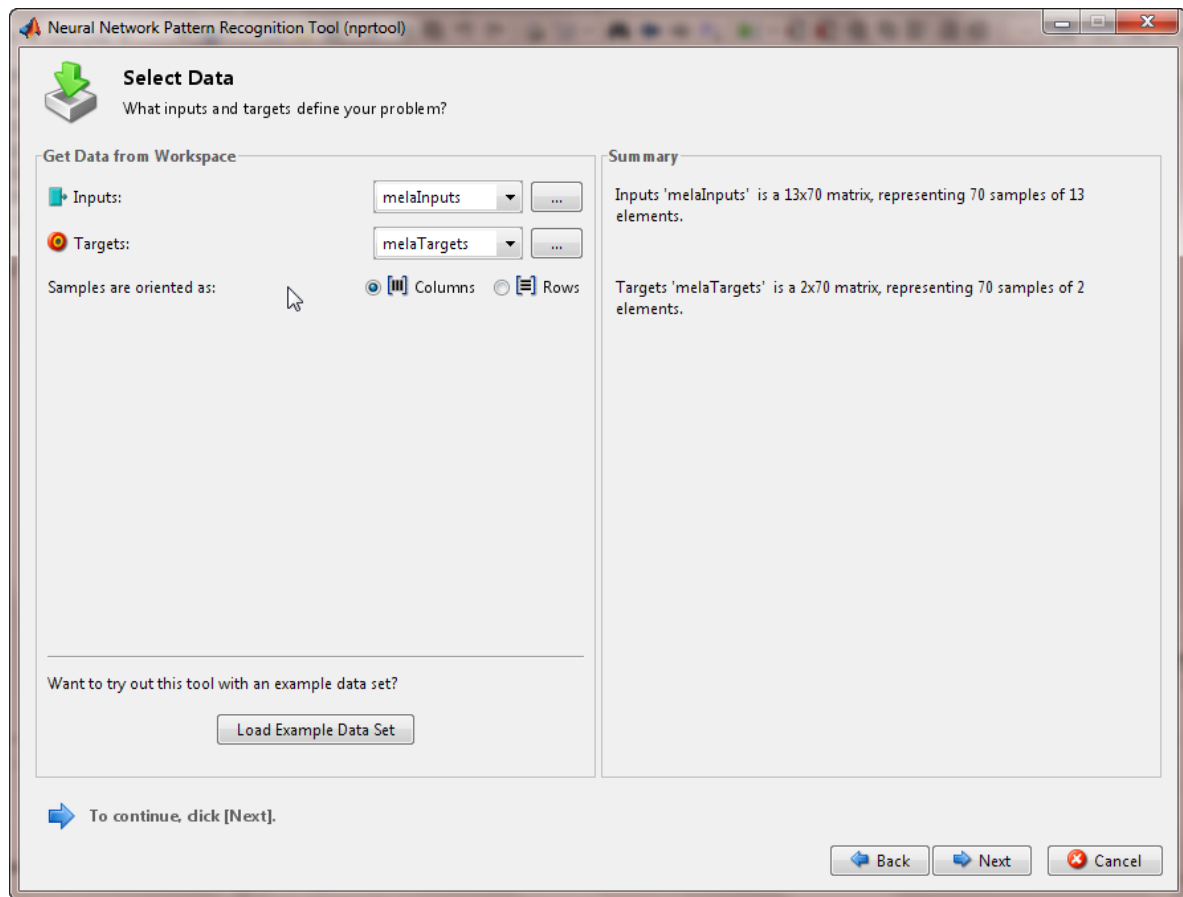
Anexo II Imágenes utilizadas para las pruebas de selección de canal y filtro



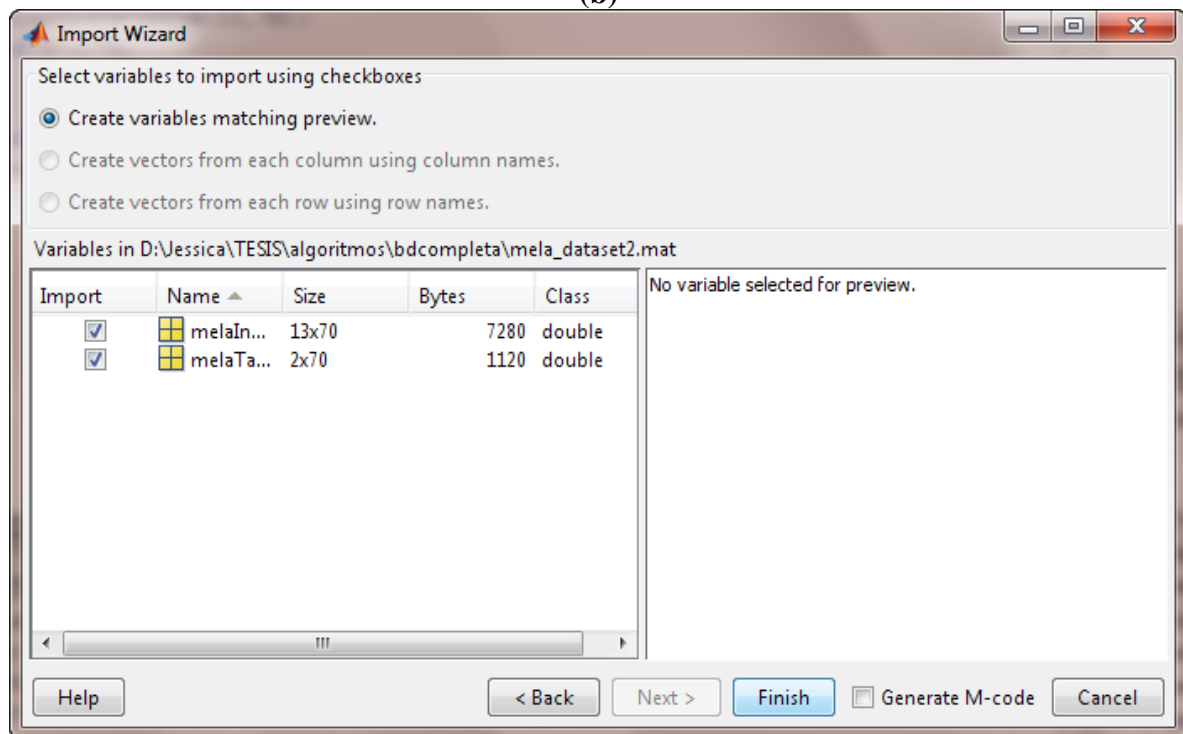
Anexo III Herramienta para reconocimiento de patrones mediante redes neuronales



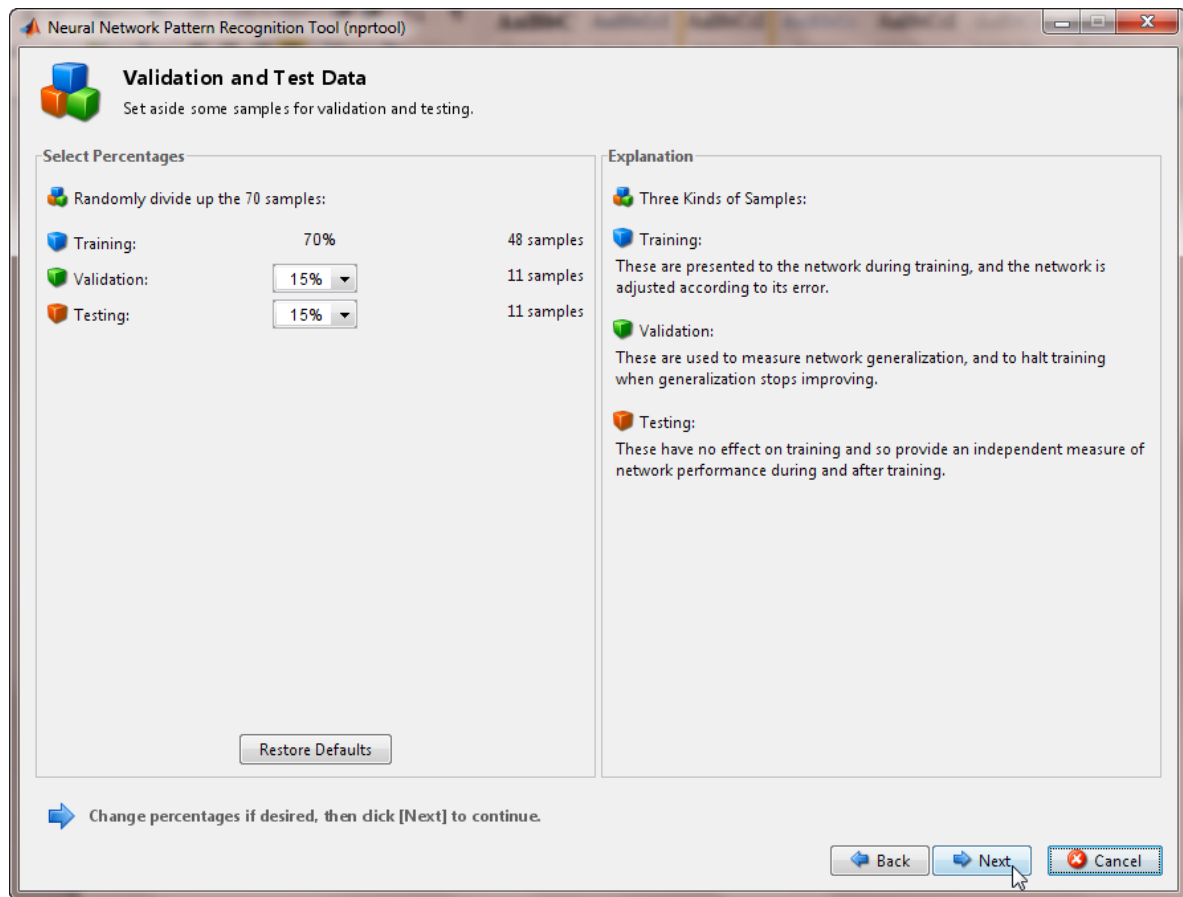
(a)



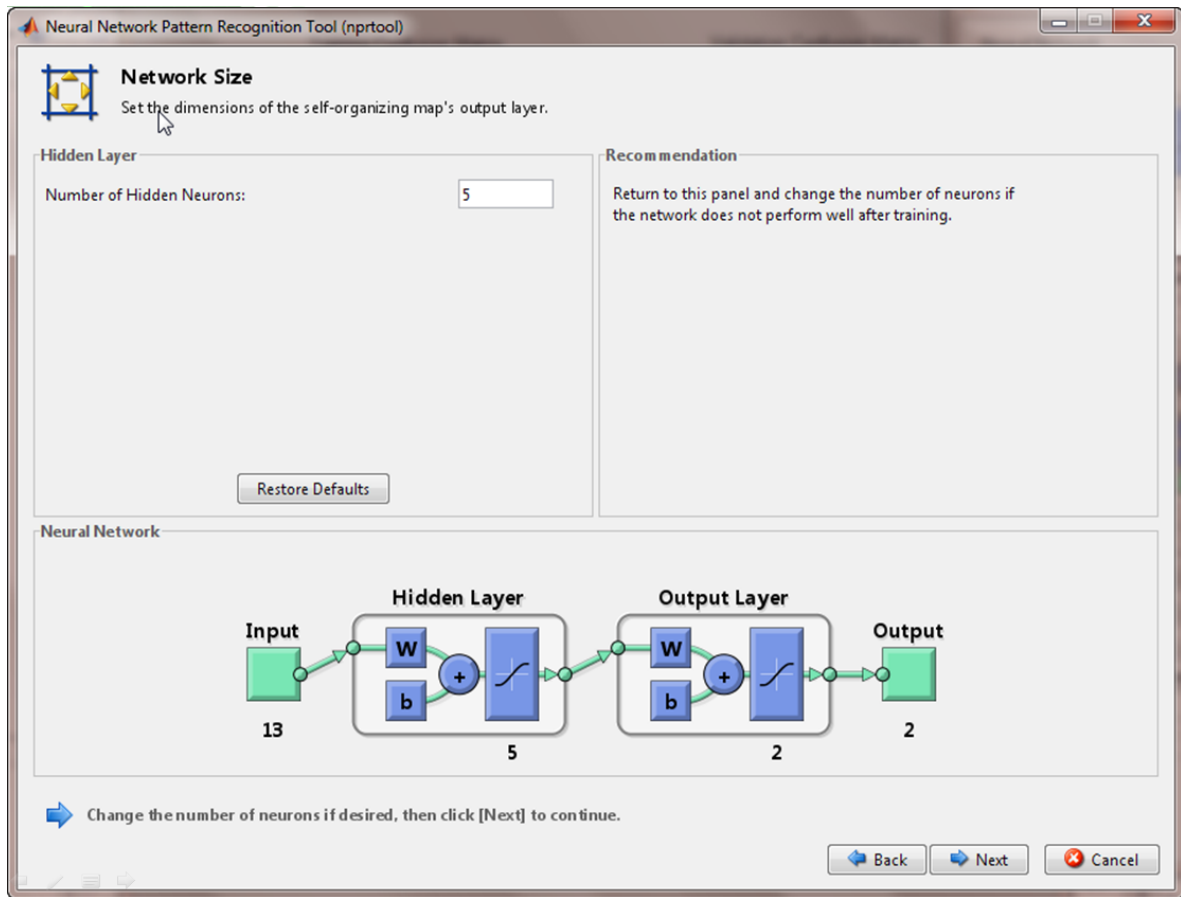
(b)



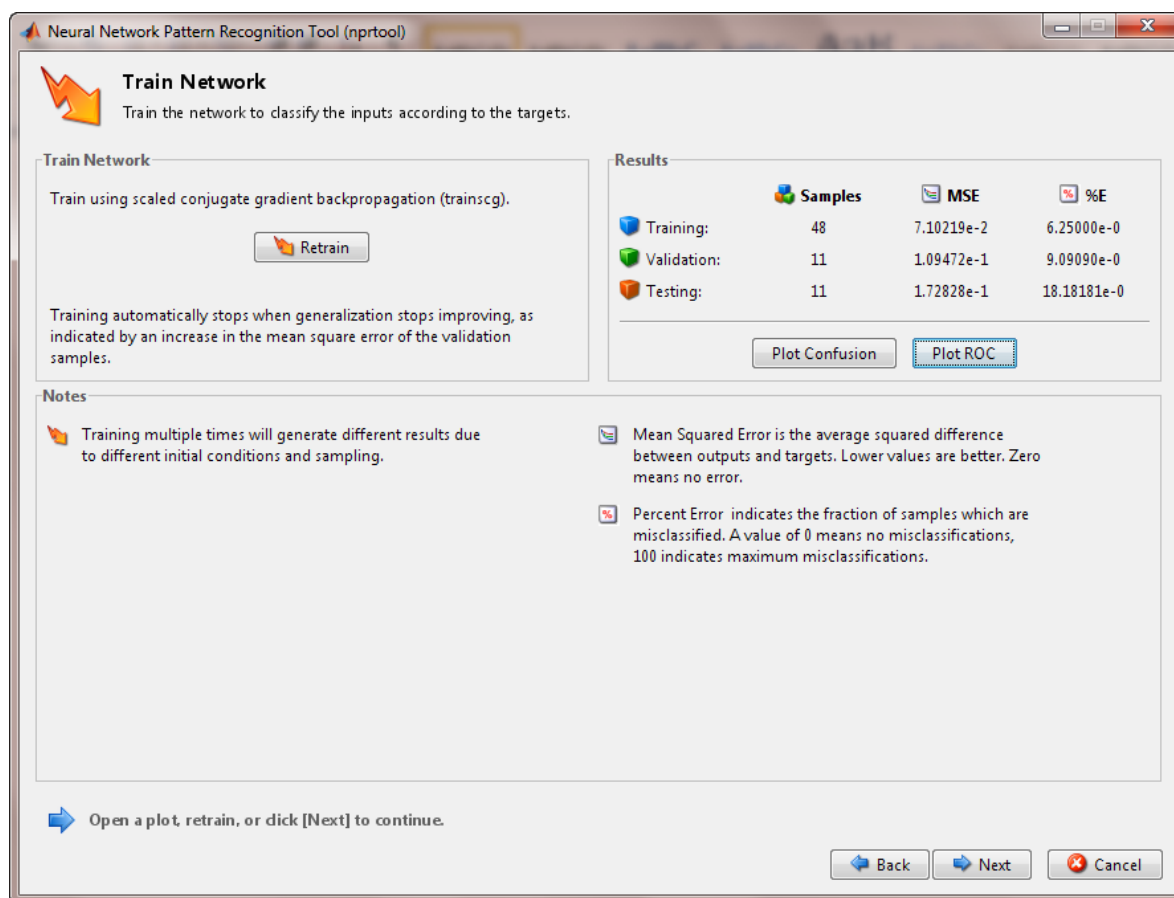
(c)



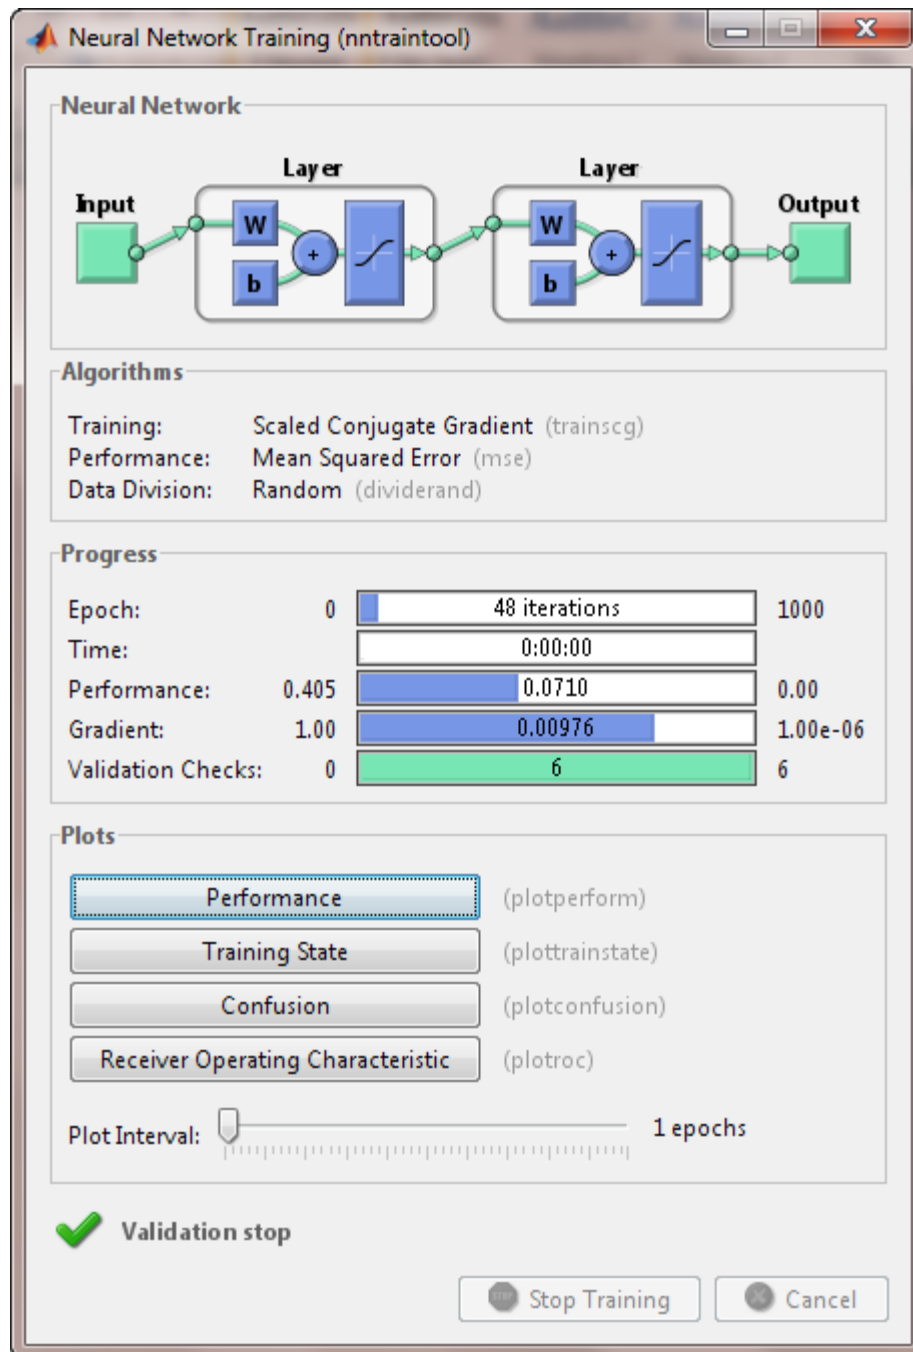
(d)



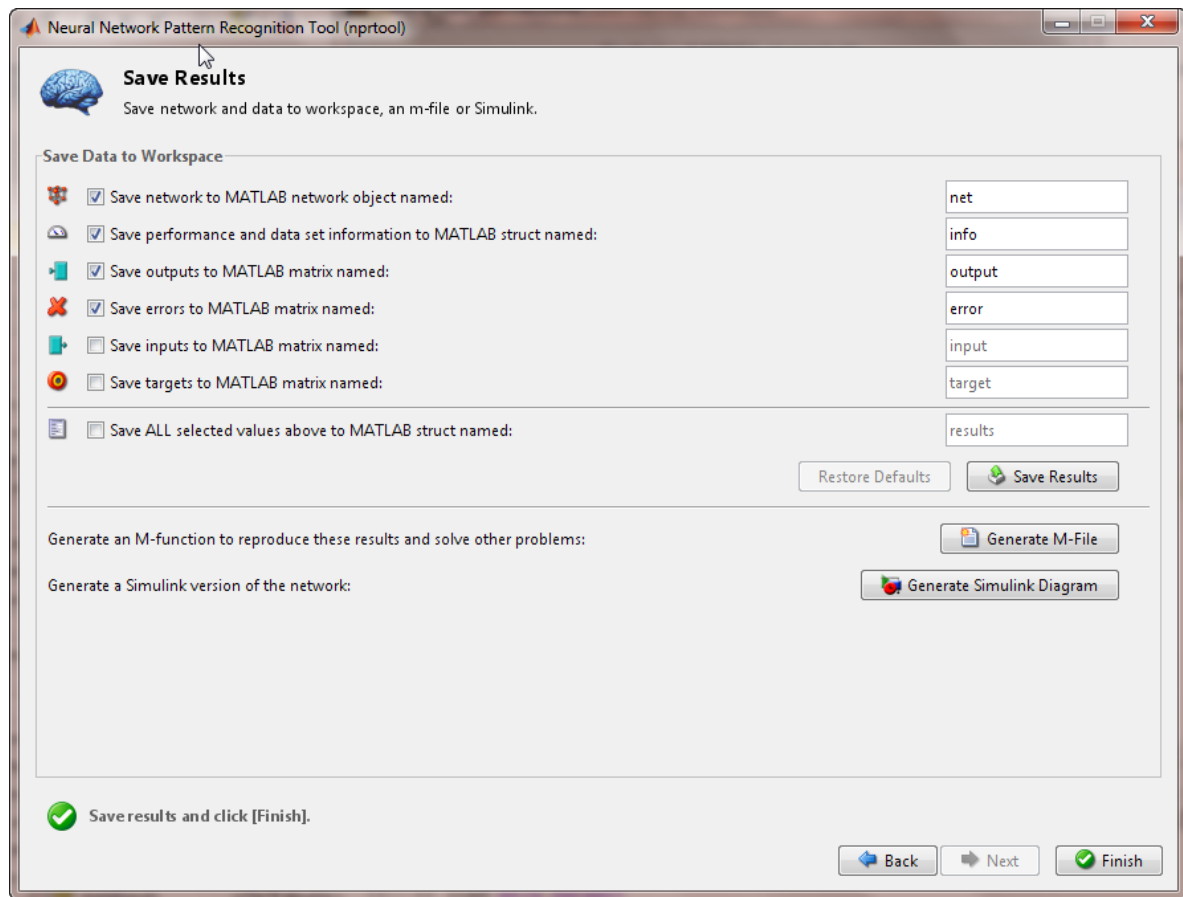
(e)



(f)



(g)



(h)

Anexo III. Rasgos y clasificación

RASGOS	i1	i2	i3	i4	i5	i6	i7	i8
perímetro de lesión, p	203	231	111	128	113	162	118	137
área de lesión, A	2083	2306	571	763	564	1391	608	819
razón 1000*p/A, pa	97.45559	100.1735	194.3958	167.7588	200.3546	116.463	194.0789	167.2772
perímetro de caja contenedora, pbb	208	238	108	122	106	168	116	140
área de de caja contenedora, Abb	2668	3534	713	930	700	1763	840	1144
varianza del lunar completo, varlun	693.0477	1375.915	749.6814	484.1534	1751.867	983.4984	1712.952	1693.585
mediana del lunar completo, medlun	90	86	41	76	103	86	75	67.5
razón desv. est. sup./inf. en %, sdud	13.7161	9.666652	33.5596	5.06706	2.316274	2.809045	2.024493	2.954914
razón desv. est. izq./der. en %, sdlr	10.34276	0.695307	9.579777	2.637738	1.370411	7.52439	10.84889	1.294744
razón medias sup./inf. en %, mud	6.896552	11.11111	7.894737	11.11111	2.970297	4.761905	4.109589	6.153846
razón medias izq./der. en %, mlr	17.07317	4.761905	18.91892	8.219178	0.487805	7.228916	7.042254	9.375
razón áreas sup./inf. en %, Aud	4.257426	13.64486	12.3871	4.683196	11.67315	11.90108	17.77778	9.075044
razón áreas izq./der. en %, Alr	5.888224	11.08033	12.3871	0.810811	14.17323	8.358663	0.682594	1.175483
Clase	benigno	benigno	benigno	benigno	benigno	benigno	benigno	benigno
Clasificación errónea	x							

Anexo III. Rasgos y clasificación

RASGOS	i9	i10	i11	i12	i13	i14	i15	i16
perímetro de lesión, p	185	214	262	217	165	156	197	289
área de lesión, A	1551	1830	3578	2748	1443	1255	1742	3911
razón 1000*p/A, pa	119.2779	116.9399	73.22527	78.96652	114.3451	124.3028	113.0884	73.89414
perímetro de caja contenedora, pbb	182	210	276	250	174	168	202	304
área de de caja contenedora, Abb	2058	2736	4725	3886	1850	1764	2550	5712
varianza del lunar completo, varlun	3639.143	997.0356	1428.149	3484.184	1162.209	1727.837	1238.567	4332.381
mediana del lunar completo, medlun	123	103	56	113	92	93	100	74
razón desv. est. sup./inf. en %, sdud	4.383117	2.52996	17.0144	1.374837	4.725779	8.96222	4.59367	1.942923
razón desv. est. izq./der. en %, sdlr	11.52588	2.32908	4.720034	0.156618	2.443015	7.819675	1.663452	2.996796
razón medias sup./inf. en %, mud	15.21739	0.980392	53.33333	2.678571	17.68293	16.47059	12.90323	5.555556
razón medias izq./der. en %, mlr	33.33333	6.060606	13.20755	1.785714	9.195402	5.555556	6.25	1.351351
razón áreas sup./inf. en %, Aud	1.182654	7.052023	6.561526	0.146735	7.737226	9.677419	11.80812	3.291536
razón áreas izq./der. en %, Alr	12.04986	1.462317	3.08193	3.127327	8.651026	2.791461	3.546099	0.877646
Clase	benigno	benigno	benigno	benigno	benigno	benigno	benigno	benigno
Clasificación errónea								

Anexo III. Rasgos y clasificación

RASGOS	i17	i18	i19	i20	i21	i22	i23	i24
perímetro de lesión, p	297	276	287	213	181	116	310	151
área de lesión, A	3993	3592	3626	2433	1762	640	4460	1084
razón 1000*p/A, pa	74.38017	76.83742	79.15058	87.54624	102.7242	181.25	69.50673	139.2989
perímetro de caja contenedora, pbb	306	288	300	226	200	114	350	152
área de de caja contenedora, Abb	5252	4988	5456	3162	2500	810	7654	1344
varianza del lunar completo, varlun	1351.559	1671.922	731.574	1253.786	1089.434	1763.811	1952.315	787.5875
mediana del lunar completo, medlun	77	77	98	65	44	33	86	31
razón desv. est. sup./inf. en %, sdud	1.837168	2.436937	8.751567	5.770245	5.956568	2.283738	1.389734	10.89808
razón desv. est. izq./der. en %, sdlr	0.837228	5.582927	12.27863	19.01797	13.87947	0.834197	5.541794	1.00442
razón medias sup./inf. en %, mud	1.298701	23.18841	3.125	9.677419	14.63415	16.12903	12.34568	6.666667
razón medias izq./der. en %, mlr	2.631579	10.9589	8.602151	24.54545	17.5	1.515152	6.024096	3.333333
razón áreas sup./inf. en %, Aud	4.372428	4.114286	5.353075	2.432886	6.871463	9.608541	5.050038	10.56478
razón áreas izq./der. en %, Alr	9.767687	1.693958	0.110988	1.419032	0.391543	5.465116	6.48062	1.590331
Clase	benigno	benigno	benigno	benigno	benigno	benigno	benigno	benigno
Clasificación errónea								

Anexo III. Rasgos y clasificación

RASGOS	i25	i26	i27	i28	i29	i30	i31	i32
perímetro de lesión, p	81	133	227	136	239	250	120	220
área de lesión, A	244	756	2198	875	2763	3164	568	2413
razón 1000*p/A, pa	331.9672	175.9259	103.2757	155.4286	86.50018	79.01391	211.2676	91.17281
perímetro de caja contenedora, pbb	70	130	226	134	252	268	112	220
área de de caja contenedora, Abb	286	1026	3190	1120	3933	4320	759	3000
varianza del lunar completo, varlun	1273.434	1120.427	2133.066	2950.613	1073.368	5494.927	1224.092	1745.921
mediana del lunar completo, medlun	56	55	67	55	43	52	31	76
razón desv. est. sup./inf. en %, sdud	0.78028	3.664917	2.828374	3.441452	0.236824	2.757326	13.91559	7.570735
razón desv. est. izq./der. en %, sdlr	7.539964	18.30122	3.858893	2.426277	1.584684	10.74657	3.450836	3.321664
razón medias sup./inf. en %, mud	8.256881	16.32653	0	1.851852	9.756098	5.882353	56	4.72973
razón medias izq./der. en %, mlr	3.636364	1.851852	6.153846	11.76471	9.756098	1.923077	29.62963	1.333333
razón áreas sup./inf. en %, Aud	20.40134	1.643836	0.275989	7.021792	1.519608	0.919393	7.162162	2.79661
razón áreas izq./der. en %, Alr	7.232704	5.586592	2.511628	11.63366	1.223691	7.89823	4.672897	7.545533
Clase	benigno	benigno	benigno	benigno	benigno	benigno	benigno	benigno

Clasificación errónea

Anexo III. Rasgos y clasificación

RASGOS	i33	i34	i35	i36	i37	i38	i39	i40
perímetro de lesión, p	247	193	150	355	238	161	305	124
área de lesión, A	2222	1721	950	4749	2905	1264	3626	620
razón 1000*p/A, pa	111.1611	112.1441	157.8947	74.75258	81.92771	127.3734	84.11473	200
perímetro de caja contenedora, pbb	248	190	146	354	252	166	300	114
área de de caja contenedora, Abb	3780	2226	1290	7812	3869	1650	5456	782
varianza del lunar completo, varlun	2132.476	1152.862	1440.101	1725.568	1112.66	675.1259	1479.608	1273.233
mediana del lunar completo, medlun	75	64	81	106	67	30	80	95
razón desv. est. sup./inf. en %, sdud	0.34922	1.044252	1.835625	29.01863	7.109642	6.679507	45.32362	25.97181
razón desv. est. izq./der. en %, sdlr	2.435347	8.174315	2.297073	23.98396	17.99247	10.62427	3.063876	22.99739
razón medias sup./inf. en %, mud	1.351351	13.33333	1.25	31.1828	12.69841	63.63636	3.797468	25
razón medias izq./der. en %, mlr	9.859155	22.80702	1.25	8.910891	0	26.92308	43.28358	7.526882
razón áreas sup./inf. en %, Aud	6.760563	3.753994	8.988764	0.084782	9.650824	5.181918	7.160731	9.059233
razón áreas izq./der. en %, Alr	28.42324	4.161665	12.81465	4.063986	3.19624	11.5975	11.43418	2.020202
Clase	benigno	benigno	benigno	maligno	maligno	maligno	maligno	maligno
Clasificación errónea								x

Anexo III. Rasgos y clasificación

RASGOS	i41	i42	i43	i44	i45	i46	i47	i48
perímetro de lesión, p	173	245	409	337	230	428	304	225
área de lesión, A	1511	1818	7919	6005	2949	8488	4231	2281
razón 1000*p/A, pa	114.4937	134.7635	51.64794	56.1199	77.99254	50.42413	71.85063	98.64095
perímetro de caja contenedora, pbb	172	218	450	356	250	456	302	232
área de de caja contenedora, Abb	1848	2950	11726	7857	3834	12980	5658	3355
varianza del lunar completo, varlun	830.4239	1136.308	821.403	1424.738	1162.358	612.8675	1278.599	1354.261
mediana del lunar completo, medlun	37	86	35	69	51	30	49	51
razón desv. est. sup./inf. en %, sdud	12.39249	8.386526	30.90235	6.11261	6.634834	7.896444	1.113155	5.624332
razón desv. est. izq./der. en %, sdlr	4.736601	29.48516	42.14561	1.001336	9.494462	5.343051	11.32094	8.010002
razón medias sup./inf. en %, mud	69.23077	2.352941	12.12121	12.30769	19.56522	90.47619	2.040816	14.58333
razón medias izq./der. en %, mlr	32.25806	7.228916	26.66667	10.60606	21.73913	10.34483	33.33333	27.27273
razón áreas sup./inf. en %, Aud	14.33481	2.099738	1.9879	1.767222	6.558533	6.811582	3.0893	9.984496
razón áreas izq./der. en %, Alr	0.920387	18.30701	10.0863	5.727074	13.01818	3.452498	1.822833	12.15539
Clase	maligno	maligno	maligno	maligno	maligno	maligno	maligno	maligno

Clasificación errónea

Anexo III. Rasgos y clasificación

RASGOS	i49	i50	i51	i52	i53	i54	i55	i56
perímetro de lesión, p	452	146	134	229	359	253	215	193
área de lesión, A	6215	1037	815	3130	4381	2734	2010	1789
razón 1000*p/A, pa	72.72727	140.7907	164.4172	73.16294	81.94476	92.53841	106.9652	107.8815
perímetro de caja contenedora, pbb	406	150	142	272	358	266	220	196
área de de caja contenedora, Abb	10212	1376	1150	4624	7770	4380	2881	2400
varianza del lunar completo, varlun	752.715	1383.103	750.9427	2567.027	849.073	1219.959	701.216	971.9424
mediana del lunar completo, medlun	43	56	22	90	45	66	58	54
razón desv. est. sup./inf. en %, sdud	8.769596	0.407285	3.089692	4.189695	1.418117	1.010806	12.63902	12.50317
razón desv. est. izq./der. en %, sdlr	3.661836	0.320493	6.262419	5.572887	11.90707	4.477489	2.502129	25.44541
razón medias sup./inf. en %, mud	9.756098	22	19.04762	5.747126	110.3448	16.39344	7.142857	3.773585
razón medias izq./der. en %, mlr	79.31034	28.57143	106.4516	1.111111	47.22222	3.076923	18.86792	81.08108
razón áreas sup./inf. en %, Aud	3.90625	6.228842	21.94418	7.826087	3.200746	7.472584	7.958115	4.16185
razón áreas izq./der. en %, Alr	6.197841	7.776262	7.001795	7.687166	9.953444	0.715519	0.808898	4.398148
Clase	maligno	maligno	maligno	maligno	maligno	maligno	maligno	maligno
Clasificación errónea	x		x		x			

Anexo III. Rasgos y clasificación

RASGOS	i57	i58	i59	i60	i61	i62	i63	i64
perímetro de lesión, p	166	246	191	176	314	248	241	230
área de lesión, A	1280	2505	1893	1753	5843	2775	3007	2697
razón 1000*p/A, pa	129.6875	98.20359	100.898	100.3993	53.73952	89.36937	80.14633	85.27994
perímetro de caja contenedora, pbb	166	242	204	198	394	240	262	248
área de de caja contenedora, Abb	1710	3604	2600	2448	9660	3564	4134	3619
varianza del lunar completo, varlun	1565.151	2405.437	744.2107	968.9494	1118.222	601.4333	863.9539	1111.161
mediana del lunar completo, medlun	45	77	26	44	51	39	24	45
razón desv. est. sup./inf. en %, sdud	0.468865	0.432904	8.511335	11.20254	0.667553	3.017636	43.16342	6.553002
razón desv. est. izq./der. en %, sdlr	14.14879	1.112206	10.96763	2.884593	17.11796	7.315241	37.37625	8.179055
razón medias sup./inf. en %, mud	2.222222	5.333333	16.66667	68.75	50	29.41176	37.5	52.94118
razón medias izq./der. en %, mlr	57.14286	10.9589	8	51.42857	73.68421	2.564103	100	39.47368
razón áreas sup./inf. en %, Aud	9.814919	1.545553	11.48343	9.124088	7.97904	0.072622	6.055684	9.145545
razón áreas izq./der. en %, Alr	17.1213	12.85796	4.552076	13.01115	5.531364	10.62691	0.157764	0.250188
Clase	maligno	maligno	maligno	maligno	maligno	maligno	maligno	maligno
Clasificación errónea	x		x					

Anexo III. Rasgos y clasificación

RASGOS	i65	i66	i67	i68	i69	i70
perímetro de lesión, p	445	381	294	258	466	402
área de lesión, A	3932	7802	4441	2503	6525	7747
razón 1000*p/A, pa	113.174	48.83363	66.20131	103.0763	71.41762	51.89105
perímetro de caja contenedora, pbb	332	412	308	258	404	426
área de de caja contenedora, Abb	6789	10584	5928	4070	10192	11286
varianza del lunar completo, varlun	785.3298	1081.519	1164.2	538.6122	342.6007	1572.739
mediana del lunar completo, medlun	85	77	70	36	86	109
razón desv. est. sup./inf. en %, sdud	9.213776	0.444279	9.477441	2.827696	17.60375	6.471811
razón desv. est. izq./der. en %, sdlr	10.21692	10.4756	2.480139	12.83766	13.11908	4.66117
razón medias sup./inf. en %, mud	3.571429	21.73913	8.955224	2.777778	2.352941	9.803922
razón medias izq./der. en %, mlr	9.876543	1.298701	1.428571	8.571429	1.176471	4.716981
razón áreas sup./inf. en %, Aud	29.30832	1.189245	2.798165	7.782427	1.955914	5.177908
razón áreas izq./der. en %, Alr	15.65601	3.02635	3.07763	18.57394	0.524044	6.714821
Clase	maligno	maligno	maligno	maligno	maligno	maligno
Clasificación errónea	x					