



FACULTAD DE INGENIERÍA Y COMPUTACIÓN

Escuela Profesional de Ciencia de la
Computación

“Redes convolucionales para la
determinación de cáncer de piel a
partir de imágenes digitales”

TESIS

Presentado por:

Rodrigo Fernandez Baca Santa Cruz

Para Optar por el Título Profesional de:

Ingeniero Informático

Asesor: “Juan Carlos Gutiérrez Cáceres”

Arequipa, diciembre del 2019

Dedicatoria

A Dios, por darme fuerzas todos los días, a mis padres que me apoyaron y estuvieron a mi lado.

Agradecimientos

Quiero agradecer a todas las personas que estuvieron a mi lado no solo durante el desarrollo de esta tesis, sino también durante toda la carrera. A mi familia, amigos y profesores por ser apoyo incondicional, guía y acompañamiento. A todos, muchas gracias.

Resumen

La automatización de sistemas de diagnóstico de cáncer de piel es de suma importancia para las personas que viven en regiones donde existe un alto índice de radiación ultravioleta como en la ciudad de Arequipa. En ese sentido el presente trabajo de tesis analiza técnicas de visión artificial y las redes convolucionales para diagnosticar el cáncer de piel a partir de imágenes digitales. Se logró automatizar ambas técnicas, la regla ABCD (muy usada por dermatólogos) y las redes neuronales convolucionales (técnica emergente muy usada en reconocimiento de imágenes). Obteniendo como mejor resultado el uso de dichas redes, llegando a un 97 % de acierto superando el 91 % del otro método (ABCD). Esto hace promisorio el uso de redes convolucionales en aplicaciones de diagnóstico por imagen.

Abstract

The automation of skin cancer diagnostic systems is of paramount importance for people living in regions where there is a high rate of ultraviolet radiation as in the city of Arequipa. In this sense, the present thesis work analyzes artificial vision techniques and convolutional networks to diagnose skin cancer from digital images. It was possible to automate both techniques, the ABCD rule (widely used by dermatologists) and convolutional neural networks (emerging technique widely used in image recognition). Obtaining as a best result the use of these networks, reaching 97% of success exceeding 91% of the other method (ABCD). This makes promising the use of convolutional networks in diagnostic imaging applications.

Introducción

Hoy en día existe una enfermedad que va en aumento progresivo en todo el mundo y tiene un índice alto de mortalidad, que preocupa mucho a las personas y es el cáncer, sin embargo son pocas las personas que realizan chequeos para poder descartar algún tipo de cáncer en el organismo, De los diferentes tipos de cáncer, uno de los más comunes, es el melanoma o cáncer de piel, esto a consecuencia del orificio en la capa de ozono que aumenta de tamaño, este orificio genera que los rayos ultravioletas generados por el sol ingresan con mayor intensidad provocando daño a la piel del ser humano, es por eso que con ayuda de la tecnología se quiere proponer una arquitectura de red convolucional, que permita diagnosticar el cáncer de piel, para así poder compararla con la técnica SBCD que es la más utilizada y confiable por los especialistas.

Palabras claves

SPC: Sociedad Peruana de Computación

CNN: Convolutional Neural Network

ABCD: Asimetría, Borde, Color y Diámetro

ABCT: Asimetría, Borde, Color y Textura

CASH: Color, Arquitectura, Simetría y Homogeneidad

RNA: Red Neuronal Artificial

SVM: Super Vector Machine

BD: Base de Datos

Índice general

1. Introducción	2
1.1. Motivación y contexto	2
1.2. Planteamiento del problema.....	4
1.3. Objetivo.....	4
1.3.1. Objetivos específicos	5
1.4. Organización de la tesis	5
2. Estado del arte	6
2.1. Consideraciones iniciales	6
2.2. Trabajos relacionados.....	7
2.2.1. Trabajos basados en <i>Deep Learning</i>	7
2.2.2. Trabajos basados en extracción de características	9
2.3. Comparaciones de los trabajos relacionados	10
2.4. Limitaciones de los trabajos relacionados.....	11
3. Marco teórico	12
3.1. Cáncer de piel o melanoma cutáneo	12
3.1.1. Estadísticas principales del cáncer de piel	14
3.1.2. Procedimientos dermatológicos para la detección de melanoma	14
3.1.3. Diagnóstico clínico usando la dermatoscopia	15
3.1.4. ABCD no automatizado	15
3.2. Procesamiento y segmentación de imágenes digitales	16
3.2.1. Definición de una imagen	16
3.2.2. Atributos de una imagen digital.....	17
3.2.3. Procesamiento de imagen.....	17
3.2.4. Segmentación	20
3.2.5. Algoritmo de Canny para la detección de bordes	21
3.3. Técnicas para la detección de melanomas	22
3.3.1. La regla ABCD	23

3.3.2.	El método de Menzies	24
3.3.3.	Lista de verificación de los 7 puntos	25
3.3.4.	Lista de los 3 puntos.....	26
3.3.5.	CASH - color, arquitectura, simetría y homogeneidad	27
3.3.6.	CHAOS y CLUES	27
3.4.	Redes neuronales	28
3.4.1.	Aplicaciones de las redes neuronales	28
3.4.2.	<i>Backpropagation</i>	29
3.4.3.	Redes convolucionales	30
3.4.4.	El futuro de las redes convolucionales	31
3.4.5.	Arquitectura de redes convolucionales	31
3.4.6.	Capas de una red convolucional.....	37
4.	Propuesta para la detección de cáncer de piel a partir de imágenes digitales	38
4.1.	Descripción de la solución propuesta	38
4.1.1.	Método Tradicional ABCD	38
4.1.2.	Método convolucional	39
4.2.	Definición de procesos con regla ABCD	40
4.2.1.	Pre procesamiento de imágenes y segmentación	40
4.2.2.	Extracción de características	43
4.2.3.	Red neuronal multicapa <i>backpropagation</i>	45
4.3.	Red neuronal convolucional	45
4.3.1.	Diseño de la red	45
4.3.2.	Arquitectura del clasificador	46
5.	Pruebas y resultados	47
5.1.	Técnicas para la determinación de cáncer de piel	47
5.2.	Proceso de evaluación	47
5.3.	Base de datos	48
5.3.1.	<i>Data augmentation</i>	48
5.4.	Segmentación de lunares benignos y malignos	49
5.5.	Extracción de características	52
5.6.	Arquitectura utilizada	54
5.7.	Resultados.....	55
6.	Conclusiones y Trabajos Futuros	61
6.1.	Conclusiones	61

6.2. Trabajos Futuros63

Bibliografía

70

Índice de tablas

2.1. Cronología de sistemas de diagnóstico de melanoma.	10
3.1. Regla ABCD	23
3.2. Método de Menzies.	25
3.3. Método 3 puntos [Ortega et al., 2012]	26
5.1. Segmentación de lunares malignos y benignos de ambas BD	52
5.2. Características ABCD de lunares malignos y benignos de ambas BD	54
5.3. Tabla de resultados de precisión de modelos CNN.	57
5.4. Comparación de los resultados entre la regla ABCD y modelo 1 CNN para la base de datos PH2Dataset.....	57
5.5. Comparación de los resultados entre la regla ABCD y modelo 1 CNN para la base de datos ISIC.....	57
5.6. Comparación de los resultados entre la regla ABCD y modelo 2 CNN para la base de datos PH2Dataset.....	58
5.7. Comparación de los resultados entre la regla ABCD y modelo 2 CNN para la base de datos ISIC.....	58
5.8. Comparación de los resultados entre la regla ABCD y modelo 3 CNN para la base de datos PH2Dataset.....	58
5.9. Comparación de los resultados entre la regla ABCD y modelo 3 CNN para la base de datos ISIC.....	58
5.10. Comparación de los resultados entre la regla ABCD y CNN para la base de datos PH2Dataset.....	59
5.11. Comparación de los resultados entre la regla ABCD y CNN para la base de datos ISIC.....	59

Índice de figuras

2.1. Dermatoscopio manual [Palacios-Martínez and Díaz-Alonso, 2017]	7
3.1. Imagen vista desde ojo clínico y dermatoscopia [Rodríguez Saa et al., 2017].	15
3.2. Imagen pixeleada [Martín, 2002]	16
3.3. Imagen en escala de grises	19
3.4. Procedimiento de dos pasos para la clasificación de lesiones cutáneas pigmentadas [López Silva et al., 2006]	22
3.5. Asimetría, Borde, Color, Diámetro y Evolución [Scharcanski and Celebi, 2013].	23
3.6. Comparación de lunares con melanomas benigno-maligno [Correa et al.,]	24
3.7. Diagnóstico de melanoma usando lista de 3 puntos [Ortega et al., 2012]	27
3.8. Arquitectura de una red neuronal [Esteva et al., 2017]	29
3.9. Interior de una red convolucional [Vargas et al., 2016]	31
3.10. Arquitectura Alexnet [Picazo Montoya, 2018]	32
3.11. Arquitectura Vggnet [Brinker et al., 2019]	33
3.12. Arquitectura GoogleNet [Kendall et al., 2015]	34
3.13. Arquitectura GoogleNet [Kendall et al., 2015]	34
3.14. Arquitectura ResNet [Szegedy et al., 2017]	35
3.15. Arquitectura ResNext [Koné and Boulmane, 2018]	36
3.16. Arquitectura Lenet [Guo et al., 2017]	36
3.17. Arquitectura Segnet [Badrinarayanan et al., 2017]	37
4.1. Método tradicional ABCD	39
4.2. Método convolucional	40
4.3. Imagen binzarizada con umbral Otsu y manual	42
4.4. Modelo de arquitectura de red a utilizar	46
5.1. Segmentación de lunar benigno.	50
5.2. Segmentación de lunar maligno	50
5.3. Segmentación de lunar benigno.	51

5.4. Segmentación de lunar maligno	51
5.5. Extracción de características ABCD lunar benigno	53
5.6. Extracción de características ABCD lunar maligno.	53
5.7. Arquitectura utilizada para la red convolucional.....	55
5.8. Modelo 1 de CNN.	55
5.9. Modelo 2 de CNN.....	56
5.10. Modelo 3 de CNN.....	56
5.11. Arquitectura utilizada para la red convolucional.....	57
5.12. Curva ROC para la precisión de la red CNN para la base de datos PH2Dataset.	59
5.13. Curva ROC para la precisión de la red CNN para la base de datos ISIC.	60

Capítulo 1

Introducción

Hoy en día existe una enfermedad que va en aumento progresivo en todo el mundo y tiene un índice alto de mortalidad, que preocupa mucho a las personas y es el cáncer, sin embargo son pocas las personas que realizan chequeos para poder descartar algún tipo de cáncer en su organismo. De los diferentes tipos de cáncer, uno de la más comunes, es el melanoma o cáncer de piel, esto a consecuencia del orificio en la capa de ozono que aumenta de tamaño, este orificio genera que los rayos ultravioletas generados por el sol ingresan con mayor intensidad provocando daño a la piel del ser humano, es por eso que con ayuda de la tecnología se quiere proponer una arquitectura de red convolucional, que permita diagnosticar el cáncer de piel, para así poder compararla con la técnica ABCD que es la más utilizada y confiable por los especialistas.

1.1. Motivación y contexto

En la actualidad la computación se encuentra aplicada fuertemente al área de la medicina. Aportando software para el apoyo en el diagnóstico de diferentes enfermedades, en estos últimos años se vienen utilizando tanto audio, imágenes y videos, registrando información con mayor interacción con los pacientes [Anibal, 2010]. Lo que viene incrementando información útil para mejorar las diferentes aplicaciones médicas. En el país la computación esta tomando un rol muy importante creando asociaciones como la Sociedad Peruana de Computación (SPC).

La computación se desarrolla en varios campos y se desarrolla en distintas áreas como la biomedicina, telecomunicaciones, electrónica, etc. En la medicina se viene desarrollando software de apoyo, como por ejemplo: sistema de registro de historias clínicas, bases de datos de pacientes, entre otros. En la actualidad una de las aplicaciones que está tomando auge en este campo es el diagnóstico por imagen, el cual puede ser utilizado en el campo de la telemedicina, ayudando a personas que viven en zonas alejadas donde la presencia de especialistas es escasa [Cañedo Andalia et al., 2005].

Se sabe que la computación está apoyando al diagnóstico de cáncer. Las muertes por cáncer está en crecimiento lo que se puede corroborar con los índices de la tasa de mortalidad de la humanidad, por eso desarrollar aplicaciones para el diagnóstico de cáncer es importante, se pudo observar muchos avances en el diagnóstico de cáncer, como por ejemplo en uno de los casos de mayor frecuencia en mujeres y a nivel mundial que es el

cáncer de mamas, que por medio de imágenes digitales (mamografías) el sistema detecta distintos tipos de formas: normales, anormales, benignas, malignas, etc, las cuales son procesadas y amplificadas. Por otro lado un grupo de científicos en computación crearon una especie de mapa del genoma del cáncer que cuenta con una gran y variada colección de información genómica y se encarga de identificar conjuntos de genes que están activos en una variedad de tumores. También la informática aporta para prevenir el cáncer del cuello uterino por medio de sistemas informáticos que ayudan a encontrar células anormales y son conocidos como *PAPNET* y *FocalPoint*, o la aplicación *DoctorMole* creada por el Doctor Mark Shippen.[Rivero, 2012]

La medicina junto con la tecnología también aportan al ámbito de los celulares móviles, gracias al avance de la tecnología en esta área, actualmente podemos encontrar una variedad de aplicaciones que pueden prevenir el cáncer, dentro de ellos encontramos a blackberry que lanzó una aplicación que fomenta información sobre el cáncer de mama, incluido un paso a paso de auto exploración, también existe el aplicativo el cual proporciona información y recomendaciones útiles para el cuidado del paciente con melanoma o cáncer, [cancer de mama y yo, 2012] te enseña a hacerte una evaluación y establece un recordatorio de cuándo debes hacerlo.

En la actualidad las aplicaciones de celulares que diagnostican cáncer tomaron un papel importante, pero indicando que son instrumentos no muy confiables ya que estos fallan la mitad de las veces en diagnosticar correctamente el estado de un lunar o mancha en la piel. La mayoría de las aplicaciones de uso similar utilizan un lenguaje confuso en su información indicando que se trata de un producto educativo cuyo resultado debe ser revisado por un médico especializado y en la mayoría de los casos, las personas competentes con del desarrollo de estas aplicaciones no se hacen responsables de ningún mal tratamiento que haya derivado del uso de la app en cuestión. [Galvez, 2016]

Así mismo hoy en día existen técnicas tradicionales que permiten apoyar el diagnóstico del cáncer de piel. Entre las técnicas más populares utilizados por los dermatólogos se encuentran: la Regla *Asimetría, Borde, Color, Diámetro* (ABCD) [Roldán-Marín et al., 2013] (*Asimetría, Borde, Color, Diámetro*, características principales que utilizan para poder saber si un lunar es cancerígeno o no), método que en la actualidad la mayoría de especialistas utilizan y se desarrollará en la presente tesis además de técnicas actuales como las redes convolucionales, que son muy efectivas para poder determinar en base a ambos métodos un diagnóstico efectivo. Automatizar el regla ABCD tiene un grado de dificultad al determinar cuándo un lunar es asimétrico, o cual debe ser el borde determinado, la intensidad del color y el tamaño del diámetro que deberán ser bien definidos para poder dar un buen diagnóstico de cáncer, método de Menzies [Menzies et al., 1996] y lista de los siete puntos [Martínez Martínez, 2014] desarrollada en Glasgow en 1980, son otros métodos de examinación desarrollados para ayudar a personas que no son profesionales en la materia en la determinación de cáncer o no.

En cuanto a los sistemas de detección de cáncer de piel que apoyen al diagnóstico del médico especialista, se encontraron sistemas que puedan apoyar eficientemente a esta labor [Manuel, 2013]; y aún más que tengan un apoyo probabilístico, el problema se basa en la cantidad de elementos que componen las bases de datos así como también el uso de distintas base de datos que en algunos casos no son validadas por médicos profesionales de la materia.

El diagnóstico de los lunares por parte de médicos especialistas en detección de

cáncer de piel, es determinado en base al conocimiento empírico resaltando las características del lunar, por medio del método (ABCD) [Roldán-Marín et al., 2013], por lo que el analizar para extraer la asimetría, el borde, el color y el diámetro de una imagen hace que se dificulte por distintos motivos como: calidad de la imagen, distancia de enfoque de imagen, estructura, maticidad, ruido, etc.

Por otro lado las redes convolucionales son una técnica del aprendizaje de máquina que hoy en día está siendo muy usada en el área de visión artificial, solucionando muchos problemas mejor que las técnicas tradicionales es por eso que comparar su desempeño en aplicaciones médicas sería de suma importancia, por los buenos resultados que se obtienen.

1.2. Planteamiento del problema

Uno de los desafíos de la ciencia de la computación es simular el sistema visual humano, en ese sentido desarrollar sistemas de visión artificial, sería de mucha utilidad en los sistemas de diagnóstico médico. El problema es implementar y proponer algoritmos que simulen el sistema de diagnóstico automático de cáncer de piel, está en la extracción de características en base a como la haría un médico, el cual toma en consideración los siguientes factores:

- Como implementar un algoritmo para determinar si una lesión es simétrica a partir de una imagen digital, es necesario realizar un proceso de segmentación, ahora bien es sabido que dicho proceso es subjetivo y automatizarlo complicado, pero si la segmentación realizada falla entonces la simetría no será la correcta.
- Desarrollar técnicas computacionales para definir si el borde es de forma irregular. Las lesiones no determinan claramente los límites de la lesión siendo subjetivo en algunos casos, lo que es diferente trabajar con imágenes de bordes definidos, aún así la determinación de este es complicado.
- Proponer un algoritmo para detectar la presencia de distintos colores y determinar el rango de colores presentes en una imagen y enmarcarlas en un conjunto de colores característicos que podrían definir si una imagen corresponde a una lesión, donde es necesario analizar los espacios de color que permitan manejar los diferentes matices y pureza de colores.
- Desarrollar un algoritmo para calcular el diámetro mediante la información de las imágenes y de los dispositivos de captura, el problema se daría al no contar con una base de datos clasificada.

Es importante resaltar que al tomar fotos de las lesiones, dicho análisis puede ser automatizado con técnicas de visión computacional. Por eso el objetivo de este trabajo es presentado en la siguiente sección.

1.3. Objetivo

Proponer una arquitectura de red convolucional para diagnóstico de cáncer de piel.

1.3.1. Objetivos específicos

- Implementar, analizar y comparar diferentes arquitecturas de red convolucional.
- Determinar la arquitectura más eficaz.
- Comparar la arquitectura de red convolucional seleccionada con la técnica ABCD.

1.4. Organización de la tesis

Esta tesis está dividida por 5 capítulos, los cuales se definen brevemente a continuación:

- En el segundo capítulo se mencionan los trabajos relacionados más actuales presentando los resultados y la precisión obtenida por los diferentes métodos seleccionados.
- En el tercer capítulo se explican los métodos para capturar y digitalizar las imágenes de las lesiones, los métodos para poder realizar la segmentación de las mismas y los métodos para poder clasificarlas y evaluarlas.
- En el cuarto capítulo se realiza la propuesta y el desarrollo del trabajo, detallando las técnicas implementadas.
- En el quinto capítulo se exponen los resultados obtenidos tras la clasificación de las lesiones realizadas para la validación de la técnica desarrollada.

Capítulo 2

Estado del arte

2.1. Consideraciones iniciales

A continuación se dan a conocer algunos trabajos encontrados en la literatura que tratan el uso de la dermatoscopia y las propuestas de sistemas de diagnóstico automatizado de cáncer de piel. Tomando en consideración las usadas en redes convolucionales y además las que se usan en procesamiento de imágenes por ser la regla ABCD, que es la más utilizada para realizar dicho diagnóstico.

Desde la aparición del cáncer de piel en Estados Unidos, a principios del siglo veinte [Ganster et al., 2001], la única manera para determinar que una persona tenga melanoma o no, era mediante una biopsia.

La biopsia, es una técnica invasiva, que consiste en realizar una extracción parcial de tejido de la zona sospechosa para así poder analizar el tipo de células que presenta por medio del microscopio, instrumento que permite observar objetos que son diminutos para ser vistos a mayor escala. En él se observan laminillas de vidrio que contienen el espécimen, observándose en un solo plano.

Se realizaron varios estudios en donde se desarrollaron diversos métodos para analizar lesiones y clasificarlas a simple vista, en 1971 se reconoce la importancia del estudio de la superficie de la piel microscópica en la evaluación pre operativa de una lesión melanocítica: nace la dermatoscopia. Numerosos grupos austríacos y alemanes continuaron estos estudios durante los años 80.

En la actualidad, se emplea para analizar lesiones dermatológicas en tiempo real, el llamado dermatoscopio manual, que es más sencillo, más económico y cómodo. Este instrumento, mostrado en la figura 2.1, contiene un sistema de lentes que aumentan de 10 a 400 veces la imagen, y un sistema de iluminación, que permite que las imágenes sean comparables y reproducibles, haciendo que las capas superficiales de la piel sean transparentes.



Figura 2.1: Dermatoscopio manual [Palacios-Martínez and D'íaz-Alonso, 2017].

En este capítulo se describe el estado del arte y trabajos que dieron origen al desarrollo de métodos de detección del cáncer de piel; se divide en investigaciones dedicadas al proceso de extracción de características y clasificadores.

2.2. Trabajos relacionados

A continuación se detalla los trabajos relacionados basados en Deep Learning y trabajos basados en procesamiento de imágenes y otros.

2.2.1. Trabajos basados en *Deep Learning*

El desarrollo tecnológico permite poder contar con uno de los mejores métodos de clasificación de imágenes y más utilizados en la actualidad, que son las redes convolucionales, dentro de la literatura relacionada se identificó en su mayoría el uso de redes ya desarrolladas que son potentes y a su vez requieren un mayor costo computacional para su uso. las redes que brindaron un mejor resultado fueron: GoogleNet y AlexNet obteniendo un porcentaje entre el 91 % al 95 %. A continuación se detalla los trabajos que utilizaron las redes convolucionales para la detección de cáncer de piel.

La Dra. Catarina Barata describió dos estrategias [Barata et al., 2014] para obtener una clasificación de lesión basada en la extracción de características locales y globales de las lesiones cutáneas. Este método implica la segmentación automática, característica, extracción y entrenamiento de un clasificador para realizar la clasificación binaria como melanoma o benigno y lograron una sensibilidad del 98 % y una especificidad del 79 % (Barata, Ruela, Francisco, Mendonca y Marques, 2014). Recientemente, se han propuesto métodos locales para clasificar las lesiones cutáneas de melanoma.

Tres años después un grupo de investigadores de Stanford decidió implementar un algoritmo que permita detectar visualmente y potencialmente el diagnóstico de cáncer de piel [Daignostrum, 2017], ya que el cáncer de piel va en incremento, realizaron el trabajo basándose en un algoritmo de Google utilizando imágenes de internet con distintas

características. Compilando una cantidad de 2000 imágenes con enfermedades diferentes, crearon una red neuronal convolucional que le permita clasificar las lesiones de la piel utilizando como entrada los píxeles y las etiquetas que indicaban la enfermedad, corroborando luego estos resultados con dermatólogos profesionales, llegando a un 91 % de sensibilidad y especificidad. Sin embargo en este trabajo se utilizó demasiado recurso computacional para poder dar un porcentaje alto de veracidad a diferencia de trabajo realizado en esta tesis.

En el 2018 un grupo de investigadores requiere realizar la detección de cáncer de piel mediante el aprendizaje profundo [Zambrano et al., 2018], al tener que trabajar con una gran cantidad de imágenes se hace uso de redes neuronales convolucionales, haciendo uso de la arquitectura *inceptionV3*, arquitectura que fue propuesta por Google, se entrena la red neuronal y utilizan un conjunto de datos pequeños con sus etiquetas para poder evaluar la efectividad de la red neuronal obteniendo como resultados 86.90 % de exactitud, 87.47 % de precisión, 86.14 % de sensibilidad y 86.90 % de especificidad. La precisión generada por este trabajo se obtiene gracias al uso arquitecturas ya utilizadas, probadas y eficaces, lo que genera un mayor uso de recursos computacionales para lograr una mayor precisión a diferencia de la arquitectura creada en este trabajo.

Al igual que en el trabajo anterior [Zambrano et al., 2018] el uso de recursos es mayor aún, ya que en la efectividad y la capacidad de las redes neuronales convolucionales se estudiaron en clasificación de 8 enfermedades de la piel (melanoma, nevos melanocíticos, carcinoma basocelular, queratosis benigna, queratosis actínica y carcinoma intraepitelial, dermatofibroma, lesiones vasculares y nevos atípicos), donde [Rezvantab et al., 2018] utilizaron diferentes arquitecturas pre-entrenadas (*DenseNet 201*, *ResNet 152*, *Inception v3*, *InceptionResNet v2*) utilizando una cantidad de 10135 imágenes dermatoscópicas de dos bases de datos (*HAM10000*: 10015), *PH2*: 120. El objetivo es comparar la capacidad de aprendizaje profundo con el desempeño de dermatólogos altamente capacitados. En general, los resultados muestran que el aprendizaje profundo superaron a los dermatólogos en al menos el 11%. Los mejores resultados para melanoma y carcinoma basocelular son 94.40 % (*ResNet 152*) y 99.30 % (*DenseNet 201*) versus 82.26 % y 88.82 % de dermatólogos, respectivamente.

Ricardo Coronado Perez en 2018 [Pérez, 2018] busca desarrollar y proponer un método para el reconocimiento de lesiones en la piel y así lograr identificar lesiones malignas en imágenes no dermatoscópicas. Para el método se utilizó redes neuronales convolucionales y autocodificadores como método de clasificación, en sus experimentos lograron replicar resultados obtenidos con procedimientos convencionales llegando a un 90 % de especificidad y un 61 % de sensibilidad.

Jimenez Morocho en su trabajo [Jiménez and Israel, 2019] se centra en el uso de la arquitectura de la red neuronal convolucional *Inception v3* y la técnica de transferencia de aprendizaje para crear un modelo que pueda clasificar imágenes dermatoscópicas de melanoma (tumor cutáneo maligno) y nevus (tumor cutáneo benigno) con una alta exactitud. Al carecer de una gran cantidad de datos para el entrenamiento, se usa el método de aumento de datos para proveer de más información al clasificador en la ejecución de las tareas de entrenamiento y validación. Para el entrenamiento de la última capa totalmente conectada se usa el algoritmo de descenso de gradiente por mini lotes, obteniendo un alto valor de exactitud sin usar demasiados recursos computacionales, logrando una exactitud del 89,63 %. Finalmente se usa una aplicación web que sirve un recurso basado en la arquitectura REST para usar el modelo generado por parte de una aplicación móvil.

EL doctor Ardan Nugroho [Nugroho et al., 2019] en 2019 publicó su trabajo en la cual determina que la toma de decisiones para determinar la condición de la piel depende de la capacidad y el conocimiento del médico. Por lo tanto, se necesita un sistema de identificación del cáncer de piel para ayudar a tomar decisiones en la identificación del cáncer de piel. La red neuronal convolucional (CNN) se utilizó en este sistema de identificación porque puede detectar imágenes y patrones. CNN trabaja a través de tres etapas, es decir, capa convolucional, capa de agrupación y capa totalmente conectada. Este sistema de identificación se basa en la imagen de dermatoscopia del conjunto de datos de cáncer de piel HAM10000. Según esta investigación, la precisión del entrenamiento y las pruebas del sistema de identificación del cáncer de piel son del 80 % y el 78 %.

2.2.2. Trabajos basados en extracción de características

La etapa de extracción de características consiste en eliminar la redundancia de los datos. Para entender el proceso de extracción de rasgos distintivos o características, se toman en cuenta dos puntos importantes, la extracción y la selección de características. La extracción de la característica se relaciona con las técnicas encargadas de extraer las particularidades representativas de una imagen. Por otro lado, la selección de características, busca las singularidades más relevantes que mejoren la precisión en la fase de clasificación

Inicialmente algunas investigaciones hacen uso del diagnóstico clínico para la detección del cáncer de piel, mediante el análisis de imágenes dermatoscópicas. Una de las técnicas más reconocidas es la regla ABCD, basado en el análisis multivariado de cuatro criterios.

En la literatura estudiada se encuentran trabajos que estudian y utilizan el método ABCD a través de la extracción de características y las variaciones que este sufrió con el pasar del tiempo, empezando con el ABC hasta llegar a la actualidad con el uso del ABCDE que es analizado en base a la evolución del melanoma a través del tiempo. Este método es utilizado por la gran mayoría de los dermatólogos debido a la satisfacción que obtienen de sus resultados, esto a pesar del desarrollo de la tecnología y la aparición de nuevas técnicas que puedan brindar un mejor rendimiento.

El estudio comprende trabajos desde el 2003 hasta la actualidad en la que en su mayoría utilizan distintas bases de datos y una variación en la cantidad de imágenes utilizadas y su formato para realizar las pruebas correspondientes al diagnóstico de cáncer, lo que influye en el proceso de clasificación; dentro del proceso de clasificación el método que mostro mejor desempeño es el de OTSU, el cual también es utilizado en la presente tesis.

Como se mencionó anteriormente sobre la inclinación en la preferencia por el uso del método ABCD existen pocos trabajos que utilizaron soporte clínico y el método ABCT los cuales solo llegaron a una precisión del 92 % esto gracias al apoyo del clasificador *Super Vector Machine* que fue utilizado en uno de los trabajos que no aplicaron el método ABCD.

En la etapa de clasificación no existió una homogeneidad marcada ya que optaron por utilizar distintos clasificadores como el vecino más cercano, árboles de decisión, clasificador discriminante lineal, SVM y redes neuronales, logrando un 97 % como mejor desempeño. En este trabajo [Iyatomi et al., 2008], desarrollaron un sistema que realice diagnóstico en línea. El patrón inicial empleó el algoritmo automático de umbralización

para la segmentación, corrigiendo las fallas del patrón inicial, es así que reconsideraron como algoritmo de segmentación el método de crecimiento de regiones, con la finalidad de poder comparar la segmentación automática con la segmentación manual.

2.3. Comparaciones de los trabajos relacionados

Como se puede observar se realizaron distintos trabajos e investigaciones sobre la extracción de características de lunares para la determinación de melanomas, por medio de distintas técnicas. En los últimos años el procedimiento de diagnóstico de la regla ABCD ha obtenido muchas críticas, aun así este ha sido aplicado en la mayoría de sistemas de diagnóstico automático y es utilizado por la mayoría de expertos dermatólogos, la tabla 2.1 confirma la preferencia de uso de la regla ABCD.

Trabajo	Segmentación	Método	Extracción Características	Clasificador	Sensibilidad	Especificidad
Sbones 2003	Otsu	Indefinida	Geométricas, Morfológicas Cromáticas	Sistema mixto, K-NN	80.00 %	79.00 %
Iyatomi 2005	Crecimiento de Regiones	ABCD	Asimetría, Borde Color y Diámetro	RNA	87.00 %	93.00 %
celebi 2007	Otsu	Indefinido	Asimetría Compacidad	SVM	92.34 %	93.33 %
Iyatomi 2008	Crecimiento de Regiones	ABCD	Asimetría, Borde Color y Diámetro	RNA	97.00 %	86.00 %
Rahman 2008	Clustering Fuzzy C-means	Indefinido	Textura Cromática	SVM, K-NN	62.50 %	83.75 %
Alcon 2009	Otsu	ABCD	Asimetría, Borde, Color y Diámetro	K-NN	68.00 %	94.00 %
Capdehourat 2009	Otsu	ABCD, Método Argenziano	Morfológicas, Cromáticas Texturas	Arboles de decisión	75.00 %	82.00 %
Gola 2011	Doble Umbralización	ABCD	Global, locales Vello azulado, retículo	Indefinido	87.00 %	80.00 %
Capdehourat 2011	Otsu	Soporte Clínico	Color, forma, textura	Arbol de decisión	80.00 %	85.00 %
Oliveira 2012	Difusión anisotrópica Método Chan Vese	ABCT	Asimetría, Borde, Color, Textura	SVM	73.81 %	76.67 %
Batugo 2013	Clustering	ABCD	Asimetría, Borde Color, Diámetro	Clasificador Discriminante Lineal	79.31 %	71.83 %
Kanimozhi 2016	Clustering	ABCD	Asimetría, Borde Color, Diámetro	RNA	96.9 %	92.56 %
Alquran 2017	Otsu	ABCD	Asimetría, Borde Color, Diámetro	RNA	92.10 %	90.12 %
Garg 2018	Otsu	ABCD	Asimetría, Borde Color, Diámetro	RNA	95.00 %	92.00 %
Barata 2014	Aprendizaje Profundo	Redes Convolu.		Alexnet	98.00 %	79.00 %
Diagnostrum 2017	Aprendizaje Profundo	Redes Convolu.		GoogleNet	91 %	91 %
Polvillo 2018	Aprendizaje Profundo	Redes Convolu.		GoogleNet	86.14 %	86.90 %
Rezvantlab 2018	Aprendizaje Profundo	Redes Convolu.		Resnet/DenseNet	94.00 %	82.00 %
Coronado 2018	Aprendizaje Profundo	Redes Convolu.		VGG19	61.00 %	90.00 %
Jimenez 2019	Aprendizaje Profundo	Redes Convolu.		Inception V3	89.63 %	88.00 %
Nugroho 2019	Aprendizaje Profundo	Redes Convolu.		Propia	80.00 %	78.00 %

Tabla 2.1: Cronología de sistemas de diagnóstico de melanoma.

En la etapa de segmentación, según la tabla mostrada el método más utilizado fue el de Otsu. Si bien posee un índice alto de aceptación, la complejidad de las imágenes que contienen melanomas no permiten su eficiencia ya que al ser un procedimiento de umbralización, en muchos casos se pierde información relevante asociada a la lesión. Con respecto a la características de los patrones del melanoma, es frecuente el reconocimiento

mediante forma, color y textura, siendo clasificados por distintos enfoques de *machine learning* o simplemente máquinas de aprendizaje.

En mención a las redes convolucionales se evidencia que mucho depende de la arquitectura elegida, en este caso para la rama del cáncer de piel podemos observar que un mayor porcentaje de efectividad es el uso de la arquitectura AlexNet ya que esta cuenta con una mayor cantidad de convoluciones que hace que haya una mayor descomposición de la imagen para así poder obtener las características deseadas y así trabajar con la información necesaria para un diagnóstico más preciso y veraz, pero a su vez esto genera una mayor cantidad en el uso de recursos.

2.4. Limitaciones de los trabajos relacionados

Según la tabla 2.1 podemos observar que la mayoría de autores utilizaron el método de Otsu para la segmentación y la regla ABCD para la extracción de características, los cuales obtuvieron porcentajes de sensibilidad y especificidad bajos, a excepción del realizado por Iyatomi [Iyatomi et al., 2008] que su porcentaje de sensibilidad es de 97%, la limitación de estos, parte desde la base de datos utilizada, ya que en la mayoría de estas cuentan con una cantidad pequeña de imágenes para poder probarlas lo que hace que el entrenamiento no sea el adecuado y a su vez utilizan imágenes digitales tomadas desde un dispositivo fotográfico, a diferencia de la base de datos utilizada en este trabajo que son imágenes dermatoscópicas, lo que permite poder analizar de mejor manera las características y también que le permiten al ojo humano acompañada del conocimiento empírico de los expertos determinar la gravedad de las lesiones obtenidas.

También podemos encontrar trabajos similares que no siguen al menos alguna regla dermatológica para encontrar el diagnóstico, ya que proponen el estudio de características como el color y la textura del melanoma, siendo esta última no considerada en la regla ABCD: [Capdehourat et al., 2011], [Fornaciali et al., 2014], [Mera-González et al., 2014], [Abbas et al., 2013], [Kaur et al., 2015] y [Barata et al., 2014]. Esto hace que se genere un debate respecto al uso o no de métodos de diagnóstico aprobados por los dermatólogos [Capdehourat et al., 2011]. Es por eso que se propone una arquitectura de red convolucional que permita tener un mejor diagnóstico de cáncer de piel, mediante el uso de una BD con una mayor cantidad de imágenes.

Dentro de los trabajos relacionados existe un patrón muy similar con el que cuentan la gran mayoría de estos, es respecto a la base de datos utilizadas, si bien hay resultados muy buenos se podría decir que mucho depende de las bases de datos utilizadas y la cantidad de imágenes con las que cuentan estas, ya que en muchos casos las bases de datos son distintas, distintos tipos de imágenes en dimensión, calidad, etc y en otros casos el uso de más de una base de datos de pocas imágenes.

Capítulo 3

Marco teórico

Para el desarrollo del siguiente capítulo se deben tener en claro algunos conceptos los cuales serán tratados a continuación.

3.1. Cáncer de piel o melanoma cutáneo

Existen distintos tipos de cáncer dentro de ellos el cáncer de piel, que es la forma más común de cáncer en el mundo. Se identificó más de 500.000 casos nuevos con cáncer de piel al año y esto va incrementando de manera rápida, incluso más que otro tipo de cáncer. Este cáncer puede aparecer en cualquier momento y detectarse en cualquier parte del cuerpo, en la cabeza, en cara o hasta incluso en el cuello, sobre todo en partes del cuerpo que se encuentran más expuestas a los rayos ultravioletas, muchos de ellos como simples manchas y otros que deben ser considerados de peligro y deben ser atendidos con precaución [Lavanderos et al., 2018].

Australia tiene una de las tasas más altas de cáncer de piel en el mundo, casi cuatro veces más que las tasas en Canadá, los Estados Unidos y el Reino Unido [Kamangar et al., 2006]. Dos de cada tres australianos son diagnosticados con cáncer de piel a partir de los 70 años. Se han estimado 115,000 nuevos casos de diagnóstico de cáncer por año y se espera que más de 43,000 personas mueran de cáncer por año de acuerdo con el Consejo de cáncer de Australia [Fransen et al., 2012]. La Cátedra de Salud Pública declaró que más de 430,000 casos son tratados para pacientes sin melanoma, y más de 10,300 personas son tratadas por melanoma, con 1430 personas muriendo cada año.

En Perú también existen muchos casos y con el pasar del tiempo esto toma una curva ascendente. Cada año son detectados 1,200 pacientes que padecen de cáncer de piel y al menos 1,000 de estos pacientes pudieron detectar que el origen de su cáncer se debía a la excesiva exposición al sol, sin la protección adecuada. Además, cada año fallecen 500 personas víctimas de este mal, sobre todo en las zonas rurales donde es muy complicado realizar diagnósticos y donde los tratamientos necesarios muchas veces no llegan en el momento necesario [Bendezú-Sarcines et al., 2017].

Los factores de riesgo para ser propensos a tener cáncer de piel son los siguientes:

- Lunares inusuales

- Exposición a luz solar natural
- Exposición a luz ultravioleta artificial
- Antecedentes familiares o personales de melanoma
- Raza blanca y mayor de 20 años de edad
- Cabello rubio o pelirrojo
- Piel blanca o clara y pecas
- Ojos azules

Los posibles signos para determinar si es melanoma, tiene que ver con un cambio en el aspecto de un lunar o área pigmentada. Dentro de las proliferaciones melanocíticas cutáneas se encuentran lesiones comunes, como los nevus melanocíticos que son lunares comunes que en gran proporción los seres humanos poseemos.

El melanoma es un tumor maligno de melanocitos [Feng et al., 2013]. Los melanocitos producen la oscuridad del pigmento llamada melanina, quien da color a la piel. Estas células en su mayoría se encuentran en la piel, pero también se encuentran en otras partes del cuerpo, como en el intestino y el ojo. El melanoma puede originarse en cualquier parte del cuerpo que contenga melanocitos. Eso provoca en su mayoría la causa principal de las muertes relacionadas con el cáncer de piel [Jerant et al., 2000] que en porcentaje sería el 75 %. La mayoría de la aparición de melanomas o lunares malignos son a causa de una fuerte exposición al sol y más aún en personas de piel blanca [Armstrong et al., 2007].

La característica del cáncer de piel es que es una enfermedad silenciosa, es común que las personas adquirieran la lesión sin notar la evolución de la enfermedad. El factor determinante y causante de adquirir esta lesión, es el solar, pero también podemos encontrar dentro de los posibles causantes a la exposición a radiación artificial que podemos encontrar en las cabinas de bronceado. La enfermedad patológica usualmente es indoloro, se da a conocer después de tiempo de adquirirlo con la generación de un tumor debido a un crecimiento descontrolado de las células de la piel, acomodándose desde la capa más externa de la epidermis hacia adentro o viceversa, teniendo como posible consecuencia que el tumor maligno pueden afectar órganos aledaños a la lesión, algo que no ocurre con un tumor benigno.

Para poder identificar si un lunar es maligno es necesario reconocer el abultamiento o sangrado repentino de la lesión y enrojecimiento o generación de costra. Luego de su diagnóstico, la zona puede ser tratada mediante la extracción de la lesión de la región afectada. Para identificar la presencia de melanoma se trata de identificar patrones específicos sobre la lesión que sugiere la atención del especialista, el ser un procedimiento tan serio y minucioso, el proceso se torna extenuante para el diagnóstico del melanoma, también existe un tipo de análisis que corresponde al tejido maligno luego de ser extraído por medios quirúrgicos de la región afectada, esta práctica es comúnmente conocida como biopsia.

3.1.1. Estadísticas principales del cáncer de piel

El cáncer de piel está considerado como la enfermedad patológica más común entre todos los tipos de cáncer. El melanoma conforma solo 1 % de los casos de cáncer de piel, pero es causa de la gran mayoría de muertes por este tipo de cáncer.

Para el año 2018, los cálculos de la Sociedad Americana Contra El Cáncer para este cáncer en los Estados Unidos son [ANEXO et al., 2018]:

- Aproximadamente 76,380 nuevos casos de melanoma (alrededor de 46,870 en hombres y 29,510 en mujeres) se espera sean diagnosticados.
- Aproximadamente 10,130 personas (6,750 hombres y 3,380 mujeres) morirán a causa de melanoma.

La tasa de ocurrencia del melanoma ha aumentado en los últimos 30 años, la presencia del melanoma en las personas es 20 veces mayor en los blancos que en las personas de otro color de piel. En general, el riesgo de padecer melanoma en el transcurso de la vida es de aproximadamente 2.4 % (1 en 40) para personas de piel blanca, 0.1 % (1 en 1,000) para las personas de piel de color y 0.5 % (1 en 200) para los hispanos. Las tasas de incidencia son más altas en Australia / Nueva Zelanda (37 por 100.000 en 2008), donde es el tercer cáncer más común en hombres y mujeres, lo que representa uno de cada nueve (alrededor 11 % en 2008) del total de casos [Ferlay et al., 2016], al punto de constituir una de las principales causas de muerte por enfermedad cutánea [Villegas and Jaramillo, 1999].

El riesgo de padecer melanoma aumenta a medida que las personas envejecen. La edad promedio para que el melanoma se presente es de 62 años. Mientras que entre las personas menores de 30 años la aparición del melanoma es poco común. De hecho, es uno de los cánceres más comunes en los adultos jóvenes (especialmente en mujeres jóvenes).

3.1.2. Procedimientos dermatológicos para la detección de melanoma

Debido a la aparición y crecimiento de este tipo de enfermedad es que se ha concluido que los patrones más asociados a patologías melanocíticas dañinas son: retículo pigmentado prominente o atípico, puntos y glóbulos irregulares, proyecciones irregulares, estructuras de regresión, vasculares, etc [Argenziano et al., 2003].

En la práctica, existen algunos profesionales de la materia que no coinciden en tomar en cuenta las características previas, por lo cual son diversos los procedimientos de diagnóstico en los que se definen características nuevas o se eliminan otras. Además, los nuevos procedimientos son diseñados para evitar al máximo la influencia de la experiencia sobre el diagnóstico, no obstante, para los primeros métodos es fundamental contar con amplio conocimiento adquirido a través de la experiencia para ser utilizados exitosamente. De ellos, el método que tomo mayor popularidad es conocido como análisis de patrones, para diagnosticar lesiones pigmentadas de la piel, el cual tiene como característica ofrecer un diagnóstico basado en un análisis cualitativo y apoyado en la evaluación subjetiva de múltiples criterios dermatoscópicos que requieren conocimiento especial para ser identificados con suficiente seguridad [Zalaudek et al., 2006]. Con lo cual el análisis de patrones, es complejo de aplicar y es empleado principalmente por especialistas experimentados.

En el año 2000, se promovió la organización de una reunión virtual llamada *The 2Th Consensus Net Meeting on Dermoscopy*, con la que se pretendió refinar la terminología dermatoscópica, evaluar las diferentes estructuras dermatoscópicas de interés, así como los métodos diagnósticos más notables [Capdehourat et al., 2009]. Los métodos evaluados fueron: análisis de patrones, regla ABCD, método de Argenziano y lista de verificación de los 7 puntos. Los cuales serán descritos cada uno de ellos de manera más amplia.

3.1.3. Diagnóstico clínico usando la dermatoscopia

La dermatoscopia es un método que no se propaga y que permite la evaluación in vivo de colores y microestructuras de la epidermis. La lesión cutánea pigmentada está cubierta de líquido (generalmente aceite o alcohol) y examinada bajo un sistema óptico específico durante una evaluación dermatoscópica. Recientemente mediante el uso de luz polarizada en dermatoscopia con luz LED con polarización, el líquido de inmersión ya no es necesario, y algunos de estos instrumentos no necesitan contacto con la piel. Los investigadores han informado un excelente acuerdo para la mayoría de los colores de la dermatoscopia, con la excepción del velo azul-blanco y el color rosado (rojo) cuando se compara el material no polarizado y luz polarizada [Benvenuto-Andrade et al., 2007]. Concluyeron que la luz polarizada mejora la visualización de áreas rojas y vasos, especialmente este último con dermatoscopia sin contacto [Benvenuto-Andrade et al., 2007]. La figura 3.1 muestra una imagen de una lesión bajo la vista clínica (a simple vista) y la misma lesión bajo una dermatoscopia con inmersión en aceite.




Figura 3.1: Imagen vista desde ojo clínico y dermatoscopia [Rodríguez Saa et al., 2017].

3.1.4. ABCD no automatizado

En la actualidad los especialistas utilizan la experiencia para poder dar un diagnóstico inicial de lunares malignos o benignos, esta experiencia la relaciona con el método del ABCD que le permite fortalecer y llegar a un análisis más completo, el especialista analiza la asimetría del lunar en base a la forma más cercana a un círculo del lunar y esto

le permita definir si el lunar partido por la mitad hace que las dos mitades sean iguales o parecidas, en el borde define cuan irregular es este, si el borde no presenta variaciones exageradas sino al contrario que este sea constante, en el color trata de identificar una cierta cantidad de colores, si este presenta pigmentaciones de colores definidos y de más de dos colores, entonces es más propenso a que este sea una característica de ser un lunar maligno, en el diámetro se define la longitud de este o en su defecto, el crecimiento progresivo que este tiene en el tiempo.

3.2. Procesamiento y segmentación de imágenes digitales

El procesamiento digital de imágenes se define como un conjunto de técnicas aplicadas a las imágenes digitales con el objetivo de mejorar la calidad o facilitar la búsqueda de información.

3.2.1. Definición de una imagen

Una imagen digital es una fotografía, un dibujo o cualquier otra *imagen* que es convertida en un fichero de computador. Consiste en una colección ordenada de valores, estos valores representan una colección de filas de valores dispuestas ordenadamente.

Las imágenes digitales están compuestas de píxeles (abreviatura de elementos de imagen). Cada píxel representa el color (o nivel de gris para fotos en blanco y negro) en un solo punto de la imagen, por lo que un píxel es como un pequeño punto de un color particular. Midiendo el color de una imagen en un gran número de puntos, podemos crear una aproximación digital de la imagen a partir de la cual se puede reconstruir una copia del original. Los píxeles son un poco partículas de granos en una imagen fotográfica convencional, pero dispuestas en un patrón regular de las filas y columnas y almacena la información de manera algo diferente. Una imagen digital es un matriz rectangular de píxeles a veces llamado un mapa de bits. En la figura 3.2 podemos darnos cuenta de los píxeles que contiene una imagen cualquiera.



Figura 3.2: Imagen pixeleada [Martín, 2002].

3.2.2. Atributos de una imagen digital

Profundidad de color

Una imagen en color está formada por píxeles, cada uno de los cuales contiene tres números correspondientes a los niveles de rojo, verde y azul de la imagen en una ubicación particular. Rojo, verde y azul (a veces denominado RGB) son los colores primarios para mezclar luz: estos llamados colores primarios aditivos son diferentes de los colores primarios sustractivos utilizados para mezclar pinturas (cian, magenta y amarillo). Cualquier color puede ser creado mezclando las cantidades correctas de luz roja, verde y azul. Suponiendo 256 Para cada nivel primario, cada píxel de color se puede almacenar en tres bytes (24 bits) de memoria. Esto corresponde aproximadamente 16,7 millones de diferentes colores posibles.

Vecindad

Se referido a un píxel y los 8 píxeles que lo rodean. Se le llama $N_4(p)$ al conjunto formado por los píxeles verticales y horizontales vecinos del píxel p , y $ND(p)$ al conjunto de los vecinos diagonales del píxel p . A los conjuntos $N_4(p)$ y $ND(p)$ se les conoce como los 8 vecinos de p , denotado por $N_8(p)$ [Otsu, 1975].

Formas de una imagen

La forma es la apariencia de una superficie en contraposición a la materia con que está compuesta. Es el conjunto de líneas y superficies que determinan en contorno o el límite de un producto visual.

Existen distintos tipos de formas:

- Por el contorno
- Por el contenido
- Por la subjetividad

3.2.3. Procesamiento de imagen

El principal paso de procesamiento para un análisis completo de las lesiones cutáneas pigmentadas es diferenciar la lesión de la piel sana. La detección de la lesión es un problema difícil en imágenes de patología dermatoscópica como la transición entre la lesión y la piel circundante e incluso para dermatólogos entrenados, es un desafío para distinguir con precisión. Se ha observado que las imágenes de dermatoscopia a menudo contienen objetos tales como marcos de gel de dermoscopia de brillo negro, marcas de tinta, reglas, burbujas de aire, así como el desarrollo esencial que puede afectar la detección de bordes tales como vasos sanguíneos, pelos, líneas y textura de la piel. Estos objetos y elementos no relacionados complican el procedimiento de detección de borde, que resulta en la pérdida de precisión, así como un aumento en tiempo computacional. Por lo tanto, requiere algunos pasos de procesamiento previo para facilitar el proceso de segmentación

mediante la eliminación de objetos no deseados. Todo lo que podría corromper la imagen y, en consecuencia, afectar los resultados de la imagen, el procesamiento debe ser localizado y luego eliminado, enmascarado o reemplazado. Puede incluir cambio de tamaño, enmascaramiento, recorte, depilación y conversión del color *RGB* a la intensidad imagen gris, esto se hace para reducir el ruido y el efecto de los objetos de reflexión. Está destinado a facilitar la segmentación de imágenes mediante el filtrado de la imagen y la mejora de sus características importantes.

La forma más sencilla de eliminar estos artefactos es suavizar la imagen con un filtro de propósito general como filtro de grupo de pares [Celebi and Aslandogan, 2005], filtros de media, filtro de mediana [Sookpotharom, 2009] [Silveira and Marques, 2008], filtros gaussianos [Maglogiannis et al., 2006] [Erkol et al., 2005] o filtros de difusión anisotrópicos. Una solución alternativa es usar filtros que traten los píxeles como vectores [Celebi and Aslandogan, 2005]. Otra cosa notable que hace es establecer el tamaño de la máscara proporcional al tamaño de la imagen para gestionar una transacción entre suavizado de la imagen y borrosidad de los bordes. Independientemente de cuidar de todo el frente mencionado, todavía no está garantizado para obtener una imagen libre de todos los objetos. Muchos estudios sugirieron sus trabajos, muy pocos [Abbas et al., 2011] discutieron diferentes aspectos de objetos juntos pero ninguno de ellos ha discutido todos los casos de objetos o los factores que complican la detección de bordes en imágenes de dermatoscopia con contraste insuficiente. El contraste de la imagen se mejora para garantizar que los bordes de las lesiones se distingan.

Proceso de filtrado

Conjunto de técnicas englobadas dentro del pre procesamiento de imágenes cuya finalidad es obtener, a partir de una imagen origen, otra final cuyo resultado sea más adecuado para una aplicación específica mejorando ciertas características de la misma que posibilite efectuar operaciones del procesado sobre ella.

Los principales objetivos que se presentan con la aplicación de filtros son:

- Suavizar la imagen: reducir la cantidad de variaciones de intensidad entre píxeles vecinos.
- Eliminar ruido: eliminar aquellos píxeles cuyo nivel de intensidad es muy diferente al de sus vecinos y cuyo origen puede estar tanto en el proceso de adquisición de la imagen como en el de transmisión.
- Realzar bordes: destacar los bordes que se localizan en una imagen.
- Detectar bordes: detectar los píxeles donde se produce un cambio brusco en la función intensidad.

Por tanto, se consideran los filtros como operaciones que se aplican a los píxeles de una imagen digital para optimizarla, enfatizar cierta información o conseguir un efecto especial en ella.

Escala de grises

Las últimas aplicaciones de procesamiento de imágenes, como el procesamiento de imágenes médicas, el procesamiento de imágenes satelitales y el procesamiento de imágenes moleculares, utilizan diversas técnicas de procesamiento de imágenes. La conversión de imágenes en color a imágenes en escala de grises es una de las aplicaciones de procesamiento de imágenes que se utilizan en diferentes campos de manera efectiva. En la impresión de las organizaciones de publicación, una imagen en color es cara en comparación con una imagen en escala de grises. Por lo tanto, las imágenes en color se han convertido a una imagen en escala de grises para reducir el costo de impresión de los libros de edición de bajo precio. De manera similar, el visor con deficiencia de color requiere una buena calidad de imagen en escala de grises para percibir la información, como las personas normales perciben la imagen en color. Del mismo modo, varias aplicaciones de procesamiento de imágenes requieren la conversión de una imagen en color a una imagen en escala de grises para diferentes propósitos. La conversión de una imagen en color a una imagen en escala de grises requiere más conocimiento sobre la imagen en color.

Un color de píxel en una imagen es una combinación de tres colores Rojo, Verde y Azul (RGB). Los valores de color RGB se representan en tres dimensiones XYZ, ilustrados por los atributos de luminosidad, cromay tono. La calidad de una imagen en color depende del color representado por la cantidad de bits que el dispositivo digital podría admitir. La imagen de color básico representada por 8 bits, la imagen de color alto representada con 16 bits, la imagen de color verdadero representada por 24 bits y la imagen de color profundo se representan por 32 bits. El número de bits decide el número máximo de colores diferentes admitidos por el dispositivo digital. Si cada rojo, verde y azul ocupa 8 bits, la combinación de RGB ocupa 24 bits y admite 16.777.216 colores diferentes. El bit 24 representa el color de un píxel en la imagen en color. La imagen en escala de grises se ha representado mediante luminancia utilizando un valor de 8 bits. La luminancia de un valor de píxel de una imagen en escala de grises varía de 0 a 255. La conversión de una imagen en color en una imagen en escala de grises está convirtiendo los valores RGB (24 bits) en un valor de escala de grises (8 bits).

Se trata de una forma supuestamente más profesional para determinar lo que la gente llama “fotos en blanco y negro”. Con esta denominación se las distingue de las imágenes formadas por líneas que, en fotografía digital, se llaman “imágenes de mapa de bits”. Así como las escalas de gris, que se muestra en la figura 3.3.




Figura 3.3: Imagen en escala de grises.

Filtro Gaussiano

Es un efecto de suavizado para mapas de bits generado por software de edición gráfica. Este efecto es generado por medio de algoritmos matemáticos. La principal función del filtro es mezclar de manera ligera los colores de los píxeles cercanos el uno al otro, en un mapa de bits, esto hace que la imagen pierda detalles minúsculos, y así, lograr suavizar la imagen, aunque menos nítida o clara, respecto a que los bordes presentes en la imagen se ven afectados. Lo que se logra obtener es similar a una imagen tomada con una cámara fotográfica desenfocada.

Binarización por umbral

La técnica del umbral consiste en calcular la intensidad de gris correspondiente a cada píxel, previamente definiendo un umbral a partir del cual se saturaría el color: en efecto si la intensidad fuera menor o igual al umbral esta saturará a negro caso contrario si fuera mayor al umbral saturará a blanco. Esta técnica se utiliza buscando un umbral con el cual se muestren todos los objetos que se identificarán, no pudiendo distinguir uno de otro, pero si podrá distinguir de la información que no es útil del área de trabajo.

3.2.4. Segmentación

Función de umbral

La función de Umbral es una de las más importantes y sencillas técnicas de segmentación, puesto que en muchas aplicaciones de procesamiento de imágenes se requiere dividir una imagen en subregión eso dicho de otra manera reconocer la imagen, para realizar esto se utiliza la expresión mostrada en la ecuación (3.1):

$$g(x, y) = \begin{cases} 1 & \text{si } v(x, y) < t \\ 0 & \text{si } v(x, y) \geq t \end{cases} \quad (3.1)$$

Trata de una operación de reasignación g de los valores de grises de los píxeles V_{ij} comparados con respecto a un solo valor umbral t , definido.

Existen distintos tipos de técnicas para la definición del umbral dentro de ellas definimos:

- Thresholding.
- Otsu.

El *Thresholding* es el método de segmentación más simple y más comúnmente utilizado. Dado un solo umbral, t , el píxel está ubicado en la posición del enrejado (i, j) , con el valor de escala de grises f_{ij} , está asignado a categoría 1 si f_{ij} mayor igual a t . De lo contrario, el píxel se asigna a la categoría 2. En muchos casos es elegido manualmente por el científico, probando un rango de valores de t y viendo cuál funciona mejor para identificar los objetos de interés.

La segmentación implica separar una imagen en regiones (o sus contornos) correspondiente a los objetos. Por lo general, tratamos de segmentar regiones identificando propiedades. O, de manera similar, identificamos contornos identificando las diferencias entre regiones (bordes). La propiedad más simple que los píxeles de una región pueden compartir es la intensidad. Entonces, la forma más natural de segmentar tales regiones es a través del umbral, la separación de la luz y la oscuridad de regiones. El principal problema con el *Thresholding* es que consideramos solo la intensidad, y no cualquier relación entre los píxeles. No hay garantía de que los píxeles identificados por el proceso de *Thresholding* sean contiguos.

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) y tiene como objetivo calcular el valor umbral de forma que la dispersión dentro de cada clase sea lo más pequeña posible, pero al mismo tiempo la dispersión sea lo más alta posible entre clases diferentes

3.2.5. Algoritmo de Canny para la detección de bordes

Este algoritmo fue desarrollado por John F. Canny en 1986 su función es utilizar un algoritmo de múltiples etapas que permita detectar una gran cantidad de bordes en imágenes [Canny, 1986]. El propósito de Canny era descubrir el algoritmo óptimo de detección de bordes.

A continuación se lista los puntos que un detector de bordes debería cumplir para ser considerado óptimo:

1. Buena Detección: el algoritmo debe indicar el mayor número en los bordes de la imagen.
2. Buena Localización: los bordes de marca deben estar lo más cerca posible del borde de la imagen real.
3. Respuesta Mínima: El borde de la imagen solamente debe ser marcado una sola vez, y en la medida de lo posible, el ruido de la imagen no debe generar falsos bordes. Para poder cumplir con lo requerido, Canny utiliza el cálculo de variaciones, técnica que encuentra la función óptima. Función que es descrita por la suma de cuatro términos exponenciales, pero se puede aproximar por la primera derivada de una gaussiana.
4. Reducción del Ruido: El algoritmo de detección de bordes de Canny utiliza un filtro basado en la primera derivada de una gaussiana. Ya que es susceptible al ruido presente en datos de imagen sin procesar, la imagen original es transformada con un filtro gaussiano. El resultado es una imagen un poco borrosa respecto a la versión original. Esta nueva imagen no se ve afectada por un píxel único de ruido en un grado significativo.
5. Gradiente de la imagen: El borde de una imagen puede apuntar en diferentes direcciones, es por eso que el algoritmo de Canny utiliza cuatro filtros para detectar los bordes de la imagen borrosa. El operador de detección de bordes devuelve un valor

para la primera derivada en la dirección horizontal (Gy) y la dirección vertical (Gx). A partir de éste, se pueden determinar el gradiente de borde y la dirección.

3.3. Técnicas para la detección de melanomas

A lo largo de los años se han desarrollado distintas técnicas que permiten evaluar y diagnosticar los lunares en la piel en base a características obtenidas de estos con la finalidad de ayudar a especialistas o personas que no lo son en identificar que lunares tienen mayor probabilidad o no de ser melanomas. Los 5 algoritmos más comúnmente utilizados son, la regla de dermatoscopia ABCD [Stolz, 1994] [Nachbar et al., 1994]; la lista de comprobación de 7 puntos [Palacios-Martínez and Díaz-Alonso, 2017]; el método de Menzies [Menzies et al., 2003], Lista de tres puntos y el método de *Color, Arquitectura, Simetría y Homogeneidad* (CASH), después de ellos también se encuentran otros que no son populares y poco utilizados.

El procedimiento común de dos pasos para la clasificación de las lesiones pigmentadas de la piel es ilustrado en la figura 3.4. El primer paso es la diferenciación entre un melanocítico y una lesión no melanocítica.

Para detectar melanomas (y aumentar las tasas de supervivencia), se recomienda aprender la apariencia, como se ven, para estar al tanto de los lunares y verificar los cambios (forma, tamaño, color, picazón o sangrado) y para mostrar cualquier lunar sospechoso a un médico con un interés y habilidades en la malignidad de la piel.

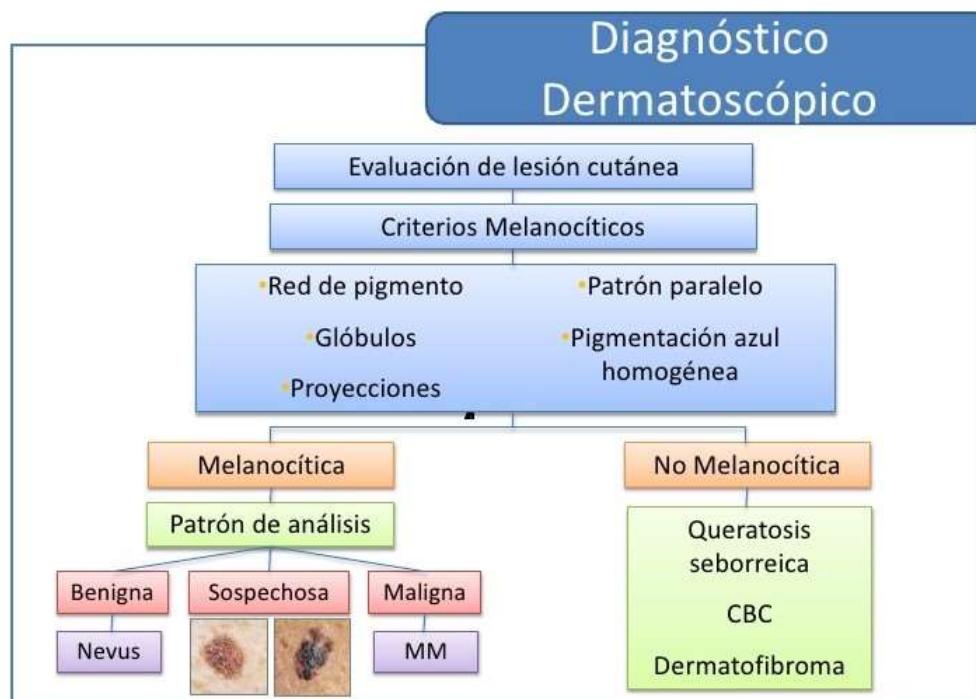


Figura 3.4: Procedimiento de dos pasos para la clasificación de lesiones cutáneas pigmentadas [López Silva et al., 2006].

3.3.1. La regla ABCD

Método de diagnóstico más utilizado por especialistas, en la cual se asigna un determinado puntaje en relación a una serie de patrones relevantes para la determinación de melanoma. Estableciendo como patrones decisivos: Asimetría, Bordes, múltiples Colores y Diámetro.

- Asimetría (A): La forma de la lesión tiende a poseer una forma irregular.
- Borde (B): Las lesiones melanocíticas poseen bordes abruptos en sus extremos. Las lesiones benignas suelen tener bordes que se desvanecen suavemente.
- Color (C): Relacionado al exceso de melanina bajo la superficie del tumor, provocando un color diferente a una concentración diferente sobre una región específica.
- Diámetro (D): Los melanomas tienen en general un diámetro mayor de 6 mm esto generado por el crecimiento descontrolado de la región.

En la figura 3.5 se puede evidenciar las características correspondientes al método ABCDE.




Figura 3.5: Asimetría, Borde, Color, Diámetro y Evolución [Scharcanski and Celebi, 2013].

Patrón	Posibles Índices	Factor de Peso
Asimetría (A)	[0-2]	1.3
Borde (B)	[0-8]	0.1
Color (C)	[1-6]	0.5
Estructuras Dermatoscópicas (D)	[1-5]	0.5

Tabla 3.1: Regla ABCD

La regla ABCD se presenta aquí en la tabla 3.1 que puede aprenderse fácilmente y calcularse rápidamente y ha demostrado ser un método confiable para proporcionar un diagnóstico más objetivo y reproducible de melanoma. Para mejorar la precisión del diagnóstico, la regla ABCDE como se muestra en la figura 3.5 de detección de lesiones se utiliza ampliamente en base a: asimetría (A), borde (B), color (C) y estructura diferencial

o Diámetro (D). Criterios de medición que deben evaluarse de forma semi cuantitativa. Entonces, cada uno de los criterios tiene que ser multiplicado por un factor de peso dado que arroja un valor de dermatoscopia total (VDT), que resulta del cálculo según la regla (1). $VDT = (\text{puntuación A} \times 1.3) + (\text{Puntuación B} \times 0.1) + (\text{Puntuación C} \times 0.5) + (\text{Puntuación D} \times 0.5) \dots$ (1) Este puntaje contribuye a la diferenciación entre lesiones benignas y malignas: menos de 4.75 - Lesión de piel benigna, de 4.75 - 5.45 - Lesión sospechosa y más de 5.45 - muy sospechoso para el melanoma.

En la siguiente figura 3.6 se muestra la comparación visual entre un lunar maligno y benigno en base a las características ABCD.



Figura 3.6: Comparación de lunares con melanomas benigno-maligno [Correa et al.,].

Se puede apreciar que para aquellos lunares benignos mantienen un patrón, siendo en su mayoría de forma circular lo que los hace a simple vista simétricos, bordes siempre regulares, colores uniformes y un tamaño promedio. Pero para los lunares malignos en su mayoría estas características varían unas con otras permitiendo un mejor diagnóstico para los profesionales.

3.3.2. El método de Menzies

Método sencillo creado en 1996 por Menzies desarrollado para hacer más sencillo el diagnóstico del melanoma y así mismo ayudar a aquellas personas que no cuenten con la suficiente experiencia para hacerlo. Con la finalidad de evitar diagnósticos equivocados en la asignación del puntaje, el método se enfoca en identificar la presencia de un conjunto de estructuras propias de la lesión maligna como se muestra en la tabla 3.2, en caso de encontrar dichas características, el diagnóstico será positivo, en caso contrario, si se encuentran las dos características asociadas a pigmentación normal, el diagnóstico será negativo a tener lunar maligno [Zaballos et al., 2004].

Con este método, para llegar al diagnóstico de melanoma, la lesión no debe presentar ninguno de las dos características negativas, es decir, la lesión no debe ser monocroma ni simétrica y además, debe presentar, al menos uno de las nueve características positivas.

Diagnóstico	Características
Benigno	Simetría de Patrones. Un color.
Maligno	Asimetría de Patrones. Más de un color. Existencia de uno o los nueve patrones positivos: 1. Velo Blanco azul. 2. Varios puntos cafés. 3. Pseudópodos. 4. Distribución radila. 5. Despигmentación tipo cicatriz. 6. Puntos negros periféricos. 7. Múltiples colores. 8. Múltiples puntos de color azul/gris. 9. Amplio pigmento reticular.

Tabla 3.2: Método de Menzies.

Como se comentó anteriormente según la tabla 3.2, estas características son de vital importancia al ser determinantes para dar un diagnóstico inicial.

3.3.3. Lista de verificación de los 7 puntos

Método semi cuantitativo creado por Argenziano en 1998 que a diferencia del método anterior este toma en cuenta 7 criterios dermatoscópicos, este método se encarga de dar una escala ordenada a los patrones que indican la existencia de melanoma sobre la lesión. Para tal fin, el procedimiento incluye características asociadas al lunar maligno con un grado de incidencia específico. A las características especialmente relacionadas con el melanoma se las llama de mayor criterio y a las menos similares se les llama características de menor criterio. A un criterio más elevado sobre la lesión, se le asigna un puntaje superior [Zaballos et al., 2004].

Lo que se quiere dar entender es que en este caso se puntúa cada característica en función de su relevancia en las lesiones malignas. El diagnóstico es positivo, es decir melanoma, en caso de que la suma de las puntuaciones de los patrones encontrados es mayor que 3.

Existen dos tipos de criterios para la evaluación de una lesión. Los criterios mayores son aquellos que tienen una puntuación de 2 y son:

- Retículo pigmentado
- Velo azul-blaquecino.
- Patrón vascular atípico.

Así mismo se encuentran los criterios mayores que cuentan con una puntuación de 1 y son:

- Proyecciones irregulares.
- Puntos/globulos irregulares.
- Manchas de pigmento irregulares.
- Estructuras asociadas a regresón.

Para el diagnóstico final aquella suma de criterios en base a su puntuación sea mayor o igual a 3 la lesión será maligna, caso contrario sera benigno.

3.3.4. Lista de los 3 puntos

En relación a los algoritmos de diagnóstico visual existentes, la lista de los tres puntos es considerado como el más simple. Se basa en evaluar 3 criterios dermatoscópicos, los cuales son: asimetría, patrón reticular atípico y por último estructuras blanco-azuladas como se muestra en 3.3. Una vez analizada la lesión con los tres criterios, esta se definirá como sospechosa si al menos aparecen dos características.

Blanca Carlos Ortega [Ortega et al., 2012] evaluó el desempeño del método presente mediante un estudio preliminar, obteniendo como conclusión que las personas sin experiencia puedan obtener valores de sensibilidad comparables a los obtenidos por los profesionales en la materia, lo cual es comprobado en [Ortega et al., 2012]. También se evaluó el método con respecto al diagnóstico conseguido por un grupo de voluntarios, dentro de este se encontraban personas profesionales asociados a la dermatología. Se realizó este estudio con la finalidad de evaluar nuevamente los resultados iniciales con un gran número de observadores. Según las pruebas realizadas se puede determinar que este método es una herramienta simple, precisa y en cierta medida apta para ser utilizada en el diagnóstico del cáncer de piel.

Lista de 3 Puntos	Definición
Asimetría	Asimetría de color y estructura, es uno o dos ejes perpendiculares
Retículo Atípico	Retículo pigmentado con orificios irregulares y líneas gruesas
Retículo Atípico	Cualquier tipo de colora irregulares y líneas gruesas

Tabla 3.3: Método 3 puntos [Ortega et al., 2012].

Los métodos mencionados fueron desarrollados no solo para ayudar a evitar el conocimiento empírico que podría conducir al conflicto de opiniones entre especialistas, sino también, para reducir la complejidad del procedimiento de diagnóstico comúnmente aceptado por los dermatólogos experimentados, análisis de patrones.

Aunque existe abundante bibliografía comparando las medidas de desempeño de los métodos de diagnóstico de melanoma, no es posible establecer su precisión real con exactitud, en vista de la variabilidad de los datos mostrados por cada investigación individual, ya sea por las estrategias de adquisición de las imágenes o sencillamente por el número de imágenes empleadas en el diagnóstico. Debido a la variabilidad de los experimentos es impropio inferir el comportamiento general de un método específico, aún más cuando se considera exclusivamente una pequeña muestra de imágenes.

En la lista de verificación de tres puntos, la presencia de dos de los tres criterios: asimetría; atípica red de pigmentos; y las estructuras blanco azulado indican que la lesión bajo investigación puede ser un melanoma, como se muestra en la figura 3.7.




Figura 3.7: Diagnóstico de melanoma usando lista de 3 puntos [Ortega et al., 2012].

3.3.5. CASH - color, arquitectura, simetría y homogeneidad

Término que encierra las palabras Color, Arquitectura, Simetría y Homogeneidad. Este es otro método que asigna puntajes a estas cuatro características y emite un diagnóstico a partir de la puntuación total.

Tras sumar la puntuación total en CASH se clasifica la lesión como:

- Probablemente benigna si la puntuación es igual o menor que 7
- Sospechosa de melanoma si la puntuación es igual o mayor que 8

3.3.6. CHAOS y CLUES

Algoritmo de diagnóstico basado en el análisis de patrones [Rosendahl et al., 2012] que toma como referencia la forma asimétrica en la estructura y/o el color de la lesión, y en la identificación de características que puedan indicar malignidad de la lesión. Se describe en primer lugar cinco características estructurales que pueden distinguirse en una lesión pigmentada, que son: líneas, pseudópodos, círculos, manchas y puntos; dentro de las líneas se distingue además cinco tipos de estructuras:

- Reticular
- Ramificada

- Paralela
- Radial
- Curvada

Por otra parte, define un total de nueve colores que pueden encontrarse en una lesión pigmentada, explicando el significado de los colores; ya que de gran importancia por la información que pueden dar sobre la profundidad de la melanina en la dermis, la presencia de sangre oxigenada etc. siendo de gran relevancia para el diagnóstico.

Este algoritmo busca la presencia de las características de caos (asimetría en color o estructura); en caso de no encontrarse, se finaliza la inspección de la muestra, concluyendo que no es lunar maligno.

3.4. Redes neuronales

Son sistemas informáticos vagamente inspirados en las redes neuronales biológicas que constituyen los cerebros de los animales. La red neuronal en sí misma no es un algoritmo, sino un marco para que muchos algoritmos de aprendizaje automático trabajen juntos y procesen entradas de datos complejos. Tales sistemas “aprenden” a realizar tareas considerando ejemplos, generalmente sin ser programados con ninguna regla específica de tareas. Por ejemplo, en el reconocimiento de imágenes, pueden aprender a identificar imágenes que contienen gatos analizando imágenes de ejemplo que se han etiquetado manualmente como “gato” o “no gato” y usar los resultados para identificar gatos en otras imágenes. Lo hacen sin ningún conocimiento previo sobre los gatos, por ejemplo, que tienen pelaje, colas, bigotes y caras de gato. En su lugar, generan automáticamente características de identificación a partir del material de aprendizaje que procesan.

Una red neuronal se basa en una colección de unidades conectadas o nodos llamados neuronas artificiales, que modelan libremente las neuronas en un cerebro biológico. Cada conexión, como las sinapsis en un cerebro biológico, puede transmitir una señal de una neurona artificial a otra. Una neurona artificial que recibe una señal puede procesarla y luego señalar neuronas artificiales adicionales conectadas a ella.

3.4.1. Aplicaciones de las redes neuronales

Las redes neuronales pueden utilizarse en un gran número y variedad de aplicaciones, pueden ser desarrolladas en un tiempo corto, realizando tareas mucho mejor que otras tecnologías. Cuando son implementadas por medio de *hardware*, presentan una alta tolerancia a fallos del sistema y proporcionan gran eficiencia en el procesamiento de datos. Esto posibilita la inserción de redes neuronales de bajo costo en sistemas existentes y recientemente desarrollados [Matich, 2001].

Hay muchos tipos diferentes de redes neuronales; cada uno de los cuales tiene una aplicación particular más apropiada, algunas aplicaciones comerciales son:

- Analizadores del habla para ayudar en la audición de sordos profundos [Matich, 2001].

- Diagnóstico y tratamiento a partir de síntomas y/o de datos analíticos (electrocardiograma, encefalogramas, análisis sanguíneo, etc.).
- Monitorización en cirugías [Palmer Pol and Montaña Moreno, 1999].
- Cáncer de Piel.
- Predicción de reacciones adversas en los medicamentos.
- Entendimiento de la causa de los ataques cardíacos [Cardenas et al., 2018].

3.4.2. Backpropagation

Backpropagation es un método utilizado en redes neuronales artificiales para calcular un gradiente que se necesita en el cálculo de los pesos que se utilizarán en la red. La propagación hacia atrás es una abreviatura de propagación de errores hacia atrás, ya que un error se calcula en la salida y se distribuye hacia atrás a través de las capas de la red. Se usa comúnmente para entrenar redes neuronales profundas [Esteva et al., 2017].

La propagación hacia atrás es una generalización de la regla delta a redes de avance de múltiples capas, que se hace posible al usar la regla de la cadena para calcular iterativamente los gradientes de cada capa. Está estrechamente relacionado con el algoritmo de Gauss-Newton y es parte de una investigación continua en la propagación neuronal.

Backpropagation es un caso especial de una técnica más general llamada diferenciación automática. En el contexto del aprendizaje, el algoritmo de optimización del descenso del gradiente utiliza comúnmente la propagación hacia atrás para ajustar el peso de las neuronas mediante el cálculo del gradiente de la función de pérdida.

En la figura 3.8 podemos observar una neurona básica en backpropagation, con sus capas de entrada, oculta y de salida. La de salida activada con una función sigmoïdal que describe valores de z entre 0 y 1.




Figura 3.8: Arquitectura de una red neuronal [Esteva et al., 2017].

3.4.3. Redes convolucionales

En la comunidad bayesiana de aprendizaje automático, se trabaja con modelos probabilísticos y de incertidumbre. Modelos como los procesos gaussianos, que definen las distribuciones de probabilidad sobre las funciones, se utilizan para conocer las formas más probables y menos probables de generalizar desde datos observados. Esta visión probabilística del aprendizaje automático ofrece límites de confianza para análisis de datos y toma de decisiones, información que un biólogo, por ejemplo, confiaría para analizar sus datos, o un automóvil autónomo utilizaría para decidir si frenar o no. Al analizar datos o tomar decisiones, a menudo es necesario poder decir si un modelo tiene certeza sobre su resultado, preguntando "¿tal vez necesite usar más datos diversos? o cambiar el modelo? o tal vez tener cuidado al tomar una decisión?". Tales preguntas son de fundamental preocupación en el aprendizaje automático Bayesiano, y han sido estudiado extensamente en el campo [Ghahramani, 2015]. Al usar modelos de aprendizaje profundo por otro lado [Goodfellow et al., 2016], generalmente solo tenemos estimaciones puntuales de parámetros y predicciones a la mano. El uso de tales modelos nos obliga a sacrificar nuestras herramientas para responder a las preguntas anteriores, lo que puede conducir a situaciones en las que no podemos decir, si un modelo está haciendo predicciones sensatas o simplemente adivinando al azar.

Ahora el aprendizaje profundo ha despertado gran interés en todos y cada uno de los campos, y especialmente en el análisis de imágenes médicas. Por lo tanto, para el año 2021, se obtendrá más inversión para imágenes médicas que toda la industria de análisis pasó en 2016. Es el enfoque de aprendizaje automático más eficaz y supervisado. Este enfoque usa los modelos de uso de la red neuronal profunda que es la variación de la red neuronal pero con una gran aproximación al cerebro humano mediante el mecanismo de avance como comparar a la red neuronal simple. El término deep learning implica el uso de un modelo de red neuronal profunda. La unidad computacional básica en una red neuronal es la neurona, un concepto inspirado en el estudio del cerebro humano, que toma múltiples señales como entradas, las combina linealmente usando pesos, y luego pasa las señales combinadas a través de operaciones no lineales para generar señales de salida [García Ferrando, 2017].

Las redes convolucionales (*Convolutional neural network* (CNN)) están diseñados para procesar datos que vienen en forma de matrices múltiples, por ejemplo, una imagen en color compuesta por tres matrices 2D que contienen intensidades de píxeles en los tres canales de color. Muchas modalidades de datos se encuentran en forma de matrices múltiples: 1D para señales y secuencias, incluido el lenguaje; 2D para imágenes o espectrogramas de audio; y 3D para video o imágenes volumétricas. Hay cuatro ideas clave detrás de *ConvNets* que aprovechan las propiedades de los recursos naturales señales: conexiones locales, pesos compartidos, agrupamiento y el uso de muchas capas. La arquitectura de una *ConvNet* típica como se muestra en la figura 3.9 está estructurada como serie de etapas. Las primeras etapas se componen de dos tipos de capas: capas convolucionales y capas de agrupamiento. Unidades en una capa convolucional están organizados en mapas de características, dentro de las cuales cada unidad está conectado a parches locales en los mapas de características de la anterior capa a través de un conjunto de pesos llamado banco de filtros.




Figura 3.9: Interior de una red convolucional [Vargas et al., 2016].

3.4.4. El futuro de las redes convolucionales

El aprendizaje no supervisado tuvo un efecto catalizador en revivir el interés en aprendizaje profundo, pero desde entonces ha sido eclipsado por los éxitos de aprendizaje puramente supervisado. Aunque no nos hemos centrado en esto en esta Revisión, esperamos que el aprendizaje no supervisado sea mucho más importante a más largo plazo. El aprendizaje humano y animal no está supervisado en gran medida: descubrimos la estructura del mundo al observarlo, no al ser contados el nombre de cada objeto.

La visión humana es un proceso activo que muestrea secuencialmente la óptica matriz de una manera inteligente, específica de la tarea utilizando una pequeña y alta resolución con un gran sonido envolvente de baja resolución. Esperamos mucho del progreso futuro en la visión que vendrá de los sistemas que están entrenados de principio a fin y combine ConvNets con RNN que usan aprendizaje de refuerzo para decidir dónde mirar. Sistemas que combinan aprendizaje profundo y refuerzo aprendizaje están en su infancia, pero ya superaron sistemas de visión pasiva en las tareas de clasificación y producen impresionantes resulta en aprender a jugar muchos videojuegos diferentes. La comprensión del lenguaje natural es otra área en la que el aprendizaje profundo está a punto de tener un gran impacto en los próximos años. Esperamos sistemas que usan RNN para comprender oraciones o documentos completos será mucho mejor cuando aprendan estrategias selectivamente atendiendo a una parte a la vez.

En última instancia, se producirán grandes avances en la inteligencia artificial a través de sistemas que combinan el aprendizaje de la representación con el complejo razonamiento. Aunque el aprendizaje profundo y el razonamiento simple han sido utilizado para reconocimiento de voz y escritura durante mucho tiempo, nuevo los paradigmas son necesarios para reemplazar la manipulación basada en reglas de simbólico expresiones por operaciones en vectores grandes.

3.4.5. Arquitectura de redes convolucionales

Ahora que hemos entendido qué es una arquitectura avanzada, enumeremos las arquitecturas más importantes y sus descripciones:

AlexNet 2012

AlexNet es la primera arquitectura profunda, que introdujo uno de los pioneros en aprendizaje profundo: Geoffrey Hinton y sus colegas. Es una arquitectura de red simple pero poderosa, que ayudó a allanar el camino para la investigación pionera en Deep Learning como lo es ahora. Aquí hay una representación de la arquitectura propuesta por los autores.

Cuando se descompone, *AlexNet* parece una arquitectura simple con capas convolucionales y de agrupación una encima de la otra, seguidas de capas completamente conectadas en la parte superior. Esta es una arquitectura muy simple, que se conceptualizó en los años ochenta. Lo que distingue a este modelo es la escala en la que realiza la tarea y el uso de la GPU para el entrenamiento. En 1980, la GPU se utilizó para entrenar una red neuronal. Mientras que *AlexNet* acelera el entrenamiento 10 veces solo con el uso de la GPU. La figura 3.10 demuestra lo indicado.




Figura 3.10: Arquitectura Alexnet [Picazo Montoya, 2018].

Cuando se descompone, *AlexNet* parece una arquitectura simple con capas convolucionales y de puesta en común una encima de la otra, seguidas de capas completamente conectadas en la parte superior. Esta es una arquitectura muy simple, que se conceptualizó en los años ochenta. Lo que distingue a este modelo es la escala en la que realiza la tarea y el uso de la GPU para el entrenamiento. En 1980, la GPU se utilizó para entrenar una red neuronal. Mientras que *AlexNet* acelera el entrenamiento 10 veces solo con el uso de la GPU.

Aunque está un poco desactualizado en este momento, *AlexNet* todavía se usa como punto de partida para aplicar redes neuronales profundas para todas las tareas, ya sea la visión por computadora o el reconocimiento de voz [Quintero et al., 2018].

VGGNet

La red *VGG* fue presentada por los investigadores de *Visual Graphics Group en Oxford* (de ahí el nombre *VGG*). Esta red se caracteriza especialmente por su forma piramidal, donde las capas inferiores que están más cerca de la imagen son anchas, mientras que las capas superiores son profundas.




Figura 3.11: Arquitectura Vggnet [Brinker et al., 2019].

Como la figura 3.11 representa, VGG contiene capas convolucionales posteriores seguidas de capas de agrupamiento. Las capas de agrupamiento son responsables de hacer que las capas sean más estrechas. En su artículo, propusieron múltiples tipos de redes de este tipo, con cambios en la profundidad de la arquitectura.

Las ventajas de VGG son:

- Es una muy buena arquitectura para la evaluación comparativa de una tarea en particular.
- Además, las redes preformadas para VGG están disponibles de forma gratuita en Internet, por lo que se utiliza habitualmente para diversas aplicaciones.

Por otro lado, su principal desventaja es que es muy lento para entrenar si se entrena desde cero. Incluso en una GPU decente, tomaría más de una semana hacerlo funcionar [Martínez Llamas, 2018].

GoogleNet/Inception

GoogleNet o *Inception Network*) es una clase de arquitectura diseñada por investigadores de Google. *GoogleNet* fue el ganador de *ImageNet* 2014, donde demostró ser un modelo poderoso.

En esta arquitectura, además de ir más profundo (contiene 22 capas en comparación con VGG que tenía 19 capas), los investigadores también hicieron un enfoque novedoso llamado el módulo *inception*.

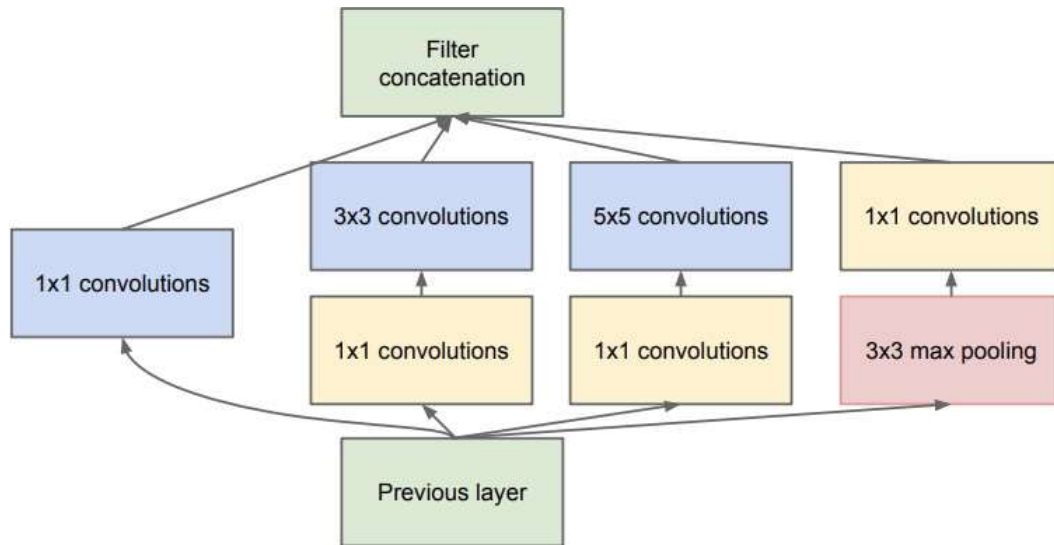


Figura 3.12: Arquitectura GoogleNet [Kendall et al., 2015].

Como se vio anteriormente en la figura 3.12, es un cambio drástico de las arquitecturas secuenciales que vimos anteriormente. En una sola capa, están presentes múltiples tipos de “extractores de características”. Esto indirectamente ayuda a la red a tener un mejor rendimiento, ya que la red en formación tiene muchas opciones para elegir al resolver la tarea. Puede elegir convolucionar la entrada o agruparla directamente.

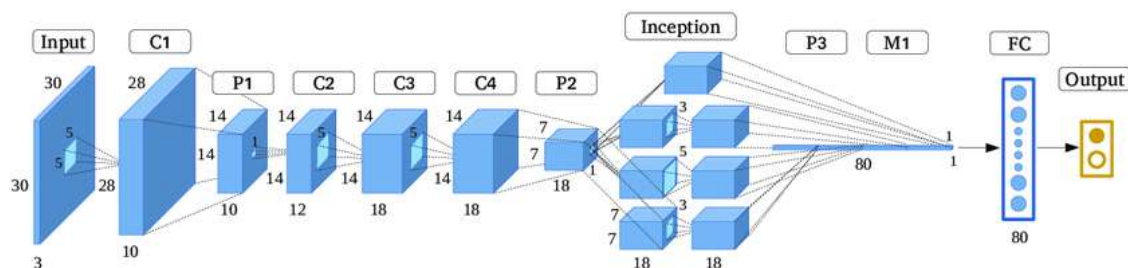


Figura 3.13: Arquitectura GoogleNet [Kendall et al., 2015].

La arquitectura final de la imagen 3.13 contiene múltiples de estos módulos de inicio apilados uno sobre el otro. Incluso el entrenamiento es ligeramente diferente en GoogleNet, ya que la mayoría de las capas superiores tienen su propia capa de salida. Este matiz ayuda a que el modelo converja más rápido, ya que hay un entrenamiento conjunto, así como entrenamiento paralelo para las capas en sí. Las ventajas de GoogleNet son:

- GoogleNet entrena más rápido que VGG.
- El tamaño de un GoogleNet preentrenado es comparativamente más pequeño que VGG. Un modelo VGG puede tener > 500 MB, mientras que GoogleNet tiene un tamaño de solo 96 MB

GoogleNet no tiene una desventaja inmediata, pero se proponen más cambios en la arquitectura, lo que hace que el modelo tenga un mejor rendimiento. Uno de estos cambios

se denomina red de *Xception*, en la que se aumenta el límite de divergencia del módulo de inicio (4 en GoogleNet como vimos en la imagen anterior). Ahora, teóricamente, puede ser infinito (por eso se lo llama inicio extremo) [Picazo Montoya, 2018].

ResNet

ResNet es una de las arquitecturas que realmente define cuán profunda puede ser una arquitectura de aprendizaje profundo. *Residual Networks* (ResNet en resumen) consta de múltiples módulos residuales posteriores, que son el elemento básico de la arquitectura ResNet. Una representación del módulo residual se ve en la figura 3.14.




Figura 3.14: Arquitectura ResNet [Szegedy et al., 2017].

En palabras simples, un módulo residual tiene dos opciones, ya sea que puede realizar un conjunto de funciones en la entrada, o puede omitir este paso por completo. Ahora, similar a GoogleNet, estos módulos residuales se apilan uno sobre el otro para formar una red completa de extremo a extremo.

Algunas otras técnicas novedosas que presentó ResNet son:

- Uso de SGD estándar en lugar de una técnica de aprendizaje adaptativa de lujo. Esto se hace junto con una función de inicialización razonable que mantiene el entrenamiento intacto.
- Cambios en el pre procesamiento de la entrada, donde la entrada primero se divide en parches y luego se alimenta a la red.

La principal ventaja de ResNet es que cientos, incluso miles de estas capas residuales se pueden utilizar para crear una red y luego capacitarse. Esto es un poco diferente de las redes secuenciales habituales, donde se ve que hay actualizaciones de rendimiento reducidas a medida que aumenta el número de capas [García Jiménez et al., 2018].

ResNext

Se dice que *ResNeXt* es la técnica actual más avanzada para el reconocimiento de objetos. Se basa en los conceptos de inicio y resnet para generar una arquitectura nueva y mejorada. Debajo de la imagen hay un resumen de cómo se ve un módulo residual del módulo *ResNeXt*, como se ve en la figura 3.15 [Martín López, 2018].

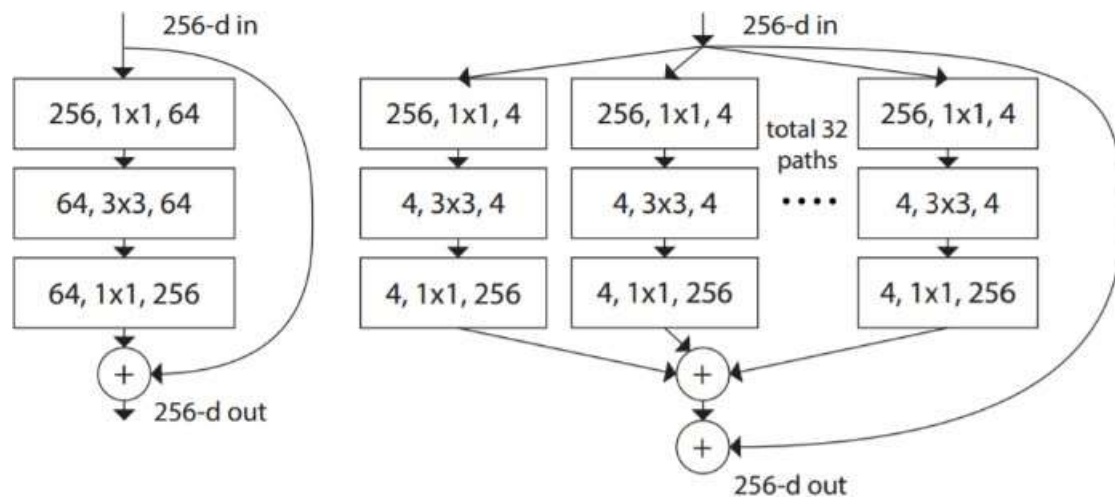


Figura 3.15: Arquitectura ResNext[Koné and Boulmane, 2018].

LeNet-5

Es una red convolucional pionera de 7 niveles, que clasifica los dígitos según la figura 3.16. Fue aplicada por varios bancos para reconocer números escritos a mano en cheques digitalizados en imágenes de entrada de escala de grises de 32×32 píxeles. La capacidad de procesar imágenes de mayor resolución requiere capas más grandes y convolucionales, por lo que esta técnica se ve limitada por la disponibilidad de recursos informáticos.




Figura 3.16: Arquitectura Lenet [Guo et al., 2017].

SegNet

SegNet es una arquitectura de aprendizaje profundo aplicada para resolver el problema de segmentación de imágenes. Consiste en una secuencia de capas de procesamiento

(codificadores) seguidas de un conjunto correspondiente de decodificadores para una clasificación en píxeles. La figura 3.17 resume el funcionamiento de SegNet.

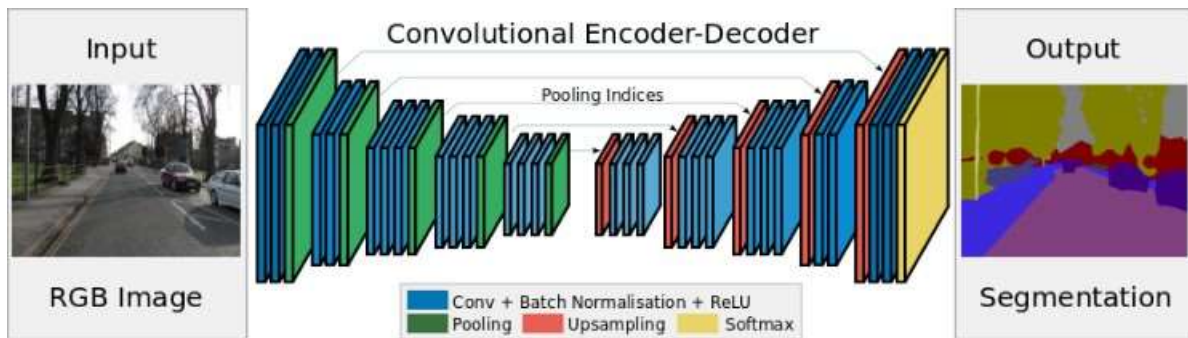


Figura 3.17: Arquitectura Segnet [Badrinarayanan et al., 2017].

Una característica clave de SegNet es que conserva los detalles de alta frecuencia en una imagen segmentada, ya que los índices de agrupamiento de la red del codificador están conectados a los índices de agrupamiento de las redes del decodificador. En resumen, la transferencia de información es directa en lugar de convulsionarlos. SegNet es uno de los mejores modelos para usar cuando se trata de problemas de segmentación de imágenes [Saez Contreras et al., 2018].

3.4.6. Capas de una red convolucional

Como se comentó anteriormente, una *ConvNet* simple es una secuencia de capas, y cada capa transforma un volumen de activaciones en otra a través de una función diferenciable. Esta red utiliza tres capas para construir arquitecturas *ConvNet*: capa convolucional, capa de agrupación y capa totalmente conectada. Estas 3 capas forman una arquitectura *ConvNet* completa.

Capítulo 4

Propuesta para la detección de cáncer de piel a partir de imágenes digitales

En secciones anteriores, se revisaron las diversas técnicas que a lo largo del tiempo se desarrollaron y descubrieron para la segmentación de imágenes digitales, extracción de características y los clasificadores más usados en el área de la medicina. Sabemos que no todas las imágenes utilizadas son limpias, muchas de ellas tienen los problemas recurrentes que suelen presentarse como el ruido, algunas manchas, brillo, sombras, etc, lo que implica tener que pasar las imágenes por filtros que suavicen la imagen y permitan extraer sus características reales que necesitamos. El filtro gaussiano es el más utilizado en este caso, dentro de todos los existentes (filtro de media, filtro mediana, filtros basados en kernels, etc). Dentro de la extracción de características pudimos ver varias técnicas dentro de ellas la técnica ABCD, Método de Menzies, Lista de los 7 puntos, Lista de los 3 puntos, etc, resaltando dentro de ellas la primera que es una de las más utilizadas y más conocidas.

4.1. Descripción de la solución propuesta

Dado que se revisó la implicancia del melanoma y la importancia de tener métodos que permitan el diagnóstico eficiente que detecten los lunares malignos, para así evitar su desarrollo. También se han explicado las arquitecturas más utilizadas en deep learning, así como también las técnicas principales de procesamiento de imágenes y clasificación automática utilizadas en el área. En base a lo indicado es que se optó por desarrollar dos métodos de análisis de imagen que permita realizar la comparación del método ABCD que es el más utilizado por los dermatólogos y el método convolucional que hace uso de redes convolucionales que hoy en día es la forma más recomendada para trabajar con imágenes y segmentarlas, es así que se detalla ambos métodos:

4.1.1. Método Tradicional ABCD

Este método cuenta con la implementación de una arquitectura nueva de red convolucional que permita complementar en la mejora del diagnóstico de lesiones malignas y

que se muestra en detalle en la figura 4.1.

- Procesamiento de imágenes digitales y extracción de características mediante aprendizaje profundo.
- Almacenar los resultados en un documento de formato de texto txt.
- Evaluar los resultados por medio de una red neuronal para así obtener la probabilidad de precisión en el diagnóstico.




Figura 4.1: Método tradicional ABCD.

4.1.2. Método convolucional

Este método es el más popular, confiable y utilizado por médicos profesionales en el análisis y diagnóstico de lesiones cancerígenas, el cual consta de los siguientes pasos (ABCD) y son mostrados en la figura 4.2:

- Definir la base de datos con la cual se trabajará.
- Procesar las imágenes para poder segmentarlas mediante los métodos: escala de grises, filtro Gaussiano, binarización y substracción.
- Definir un umbral mediante el método de Otsu y de manera manual, que permita binarizar la imagen y así poder obtener el lunar binarizado en su totalidad.
- Trabajar con las imágenes obtenidas de la substracción y binarización a las cuales se les extraerá las características de asimetría, borde, color y diámetro.
- Almacenar los resultados de la extracción de características para usarlo luego en la clasificación.
- Evaluar los resultados por medio de una red neuronal para determinar si la lesión es benigna 0 o maligna 1, convirtiendo al final el resultado en porcentaje para obtener la probabilidad de precisión en el diagnóstico.

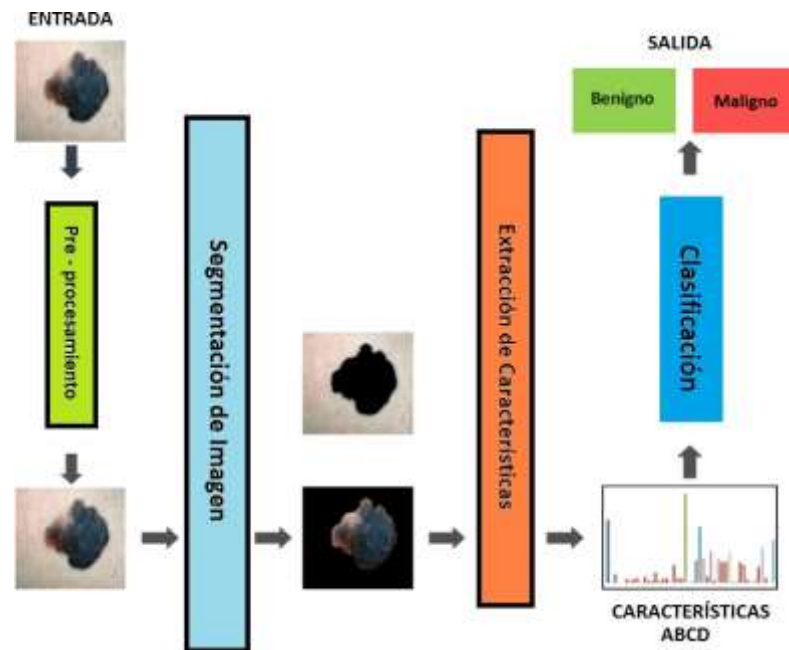


Figura 4.2: Método convolucional.

4.2. Definición de procesos con regla ABCD

Basado en los trabajos del estado del arte se propone desarrollar 4 módulos principales: Pre procesamiento, Segmentación, Extracción de características y Evaluación:

- Pre procesamiento.
- Segmentación.
- Extracción de características.
- Evaluación de resultados.

4.2.1. Pre procesamiento de imágenes y segmentación

Para poder obtener las imágenes que serán utilizadas como estudio de investigación, se clasifica a los lunares que cuenten con ciertas características que permitirán ser parte del universo de imágenes, las características son las siguientes:

- Captura de la imagen del lunar sin sombras y con buena iluminación.
- Evitar fotografiar lunares con gran cantidad de velloidad.
- El tamaño de todas las imágenes serán transformadas a un tamaño de 256×192 p'xeles.

- Se utilizarán imágenes dermatoscópicas que son utilizadas por los doctores para poder tener mayor claridad de características.

Definimos la segmentación como un conjunto de algoritmos que transforman una imagen en otra, en donde se resalta cierta información de interés, y/o se atenúa o elimina información irrelevante para la aplicación [Moya, 2012], por lo que en este proceso se realizará las siguientes funciones:

- Escala de Grises.
- Filtro Gaussiano.
- Binarización.
- Substracción.

Escala de grises

Se convierte cada pixel de la imagen en una combinación entre negro y blanco, con la finalidad de atenuar cada color de la imagen y poder trabajar directamente con el lunar, se muestra un pseudo código para poder comprender de mejor manera la implementación de la función escala de grises.

Filtro Gaussiano

La base de datos de los lunares obtenidos cuentan con distintas características que a veces suele ser difícil trabajar directamente con ellas ya que necesitamos centrarnos en las características específicas, por lo que es necesario aplicar el filtro gaussiano y de esta forma lograr el suavizado de la imagen.

Se genera un efecto similar al de una fotografía tomada con una cámara fotográfica desenfocada, esto con el fin de que el lunar sea segmentado adecuadamente, sin tener porciones en blanco en su interior.

Se llamó al número PI para poder aplicar el filtro gaussiano, por lo que se presenta el pseudo código para su comprensión

Binarización

Para poder determinar la binarización es necesario definir algún método de umbralización de la imagen para buscar un umbral óptimo que permita distinguir en una imagen los objetos del fondo de los objetos del primer plano, una vez definido el umbral será aplicado a la imagen que se le aplico el filtro gaussiano. Para poder definir el umbral se utilizan dos métodos:

- **Método Otsu** Es el método más utilizado según los trabajos relacionados por lo que se implementará para poder determinar una binarización adecuado y que incluya de preferencia la totalidad de la lesión.

- Método Manual** Se tendrá este método en caso Otsu no binarice de una manera deseada es así que se regulará el umbral de manera manual para poder encontrar la separación del lunar con el fondo y así obtener la mayor parte de la lesión.

En la figura 4.3 se visualiza la binarización realizada con los dos tipos de umbrales (OTSU y manual) la cual segmenta la lesión de distinta forma, obteniendo un mejor segmentación utilizando el umbral de manera manual, ya que esta obtiene mayor parte de la lesión a diferencia del método de OTSU.

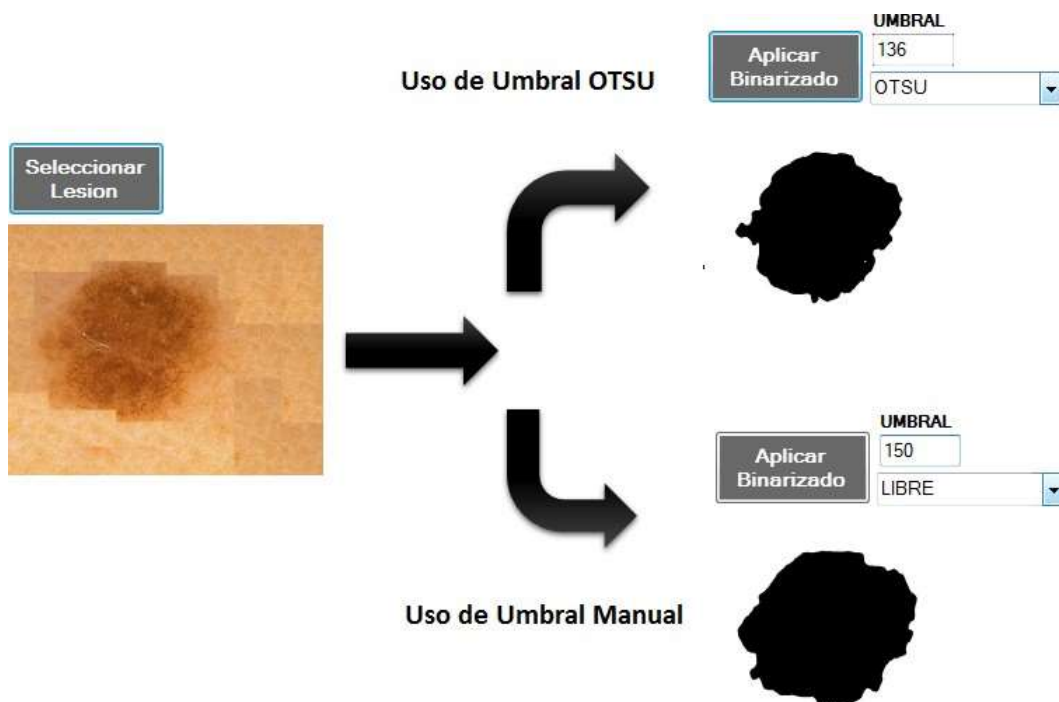


Figura 4.3: Imagen binarizada con umbral Otsu y manual.

Substracción

Por último realizamos el proceso de substracción del fondo, se crea una matriz de 0 y 1 del mismo tamaño de la imagen original poniendo valor 1 a los pixeles correspondientes al lunar y valor 0 a los pixeles correspondientes al fondo del lunar, una vez que se tiene la otra matriz se realiza la multiplicación quedando como imagen el lunar en sus colores reales y el fondo que no se utilizará de color blanco, a continuación se muestra la fórmula que realiza lo indicado anteriormente:

$$subs(n) = \begin{cases} pixel_{img} & \text{si } pixel_{bin} = 0 \\ pixel_{bin} & \text{si } pixel_{bin} = 1 \end{cases} \quad (4.1)$$

Donde $pixel_{img}$ corresponde al pixel de la imagen original y $pixel_{bin}$ al pixel de la imagen binarizada.

4.2.2. Extracción de características

En esta etapa se describirán algoritmos diseñados e implementados para la extracción de las características dermatológicas que son analizadas para la clasificación de la lesión. Debido a las limitaciones de tiempo y complejidad se ha optado por estudiar las características más relevantes. En el resto de casos se empleará directamente la información proporcionada por la base de datos, que ha sido extraída y contrastada por especialistas dermatólogos mediante inspección visual.

Asimetría

Para el proceso de obtener la asimetría del lunar, utilizaremos la imagen obtenida de la substracción del fondo, se probaron varios métodos que puedan definir si un lunar es simétrico o asimétrico: Uno de ellos era calcular la diagonal más extensa que pase por el centroide para luego comparar las sub imágenes divididas por dicha línea analizando las áreas y las semejanzas entre las figuras, pero se presentaron algunos lunares que no cumplían con este método y complicaba el objetivo de este punto. Es así que se determinó trazar una línea del punto más extremo del borde hacia el centroide y a partir de ese radio encontrado dibujar un círculo con el radio obtenido del lunar y antepone el círculo sobre el lunar

El algoritmo utilizado para poder determinar los datos correspondientes a la asimetría, satisfacería según lo siguiente:

$$\begin{aligned}
 Ce &= \text{Centroide} \\
 A &= \text{Area segmentada de la lesión} \\
 B &= \text{Area sobrante interna al círculo} \\
 C &= \text{Area sobrante externa al círculo} \\
 D &= \text{Círculo} \\
 \text{Asimetra} &= B + C
 \end{aligned}$$

Donde :

$$\begin{aligned}
 B &= D - A \in D \\
 C &= D - A \text{ s } D \\
 D &= \text{máx}(\text{diámetro } \subset Ce)
 \end{aligned}$$

Cabe mencionar que si es resultado es cercano a cero, entonces es simétrico.

Borde

En esta etapa presentaremos la técnica para hallar una de las características más importantes para la detección de cáncer de piel, existen distintas fórmulas para poder

determinar esta característica como la de la fórmula de la compacidad, el algoritmo de Canny, etc. Después de tanto análisis se decidió optar por determinar el borde con el algoritmo de Canny y generar la varianza total del arreglo de distancias obtenidos de las coordenadas del borde con el centroide, para así poder definir el rango en el cual se encuentren los valores que determinen el grado de probabilidad de cáncer referente a esa característica.

Se podrá definir el algoritmo utilizado para poder determinar los datos correspondientes al borde.

E = Borde del área segmentada

F = Vector de distancias del borde al centroide

Donde :

$$F_i = \sqrt{(E_{ix} - C_{ex})^2 + (E_{iy} - C_{ey})^2}$$

$$Media = \frac{1}{N} \sum_{i=1}^N F_i$$

$$Varianza = \frac{1}{N} \sum_{i=1}^N (F_i - Media)^2$$

Color

El índice de color se calculado convirtiendo la imagen de entrada para obtener un valor de imagen marcando por la presencia de varios colores. La longitud de todos los píxeles disponibles con valores dados son divididos por el número total de píxeles, la presencia del color depende del valor de la resultante en que esta no sea igual a cero . Para cada color la presencia del índice de color es igual a 1. El crecimiento de la variación del color es un signo temprano de melanoma.

Debido a que las células del melanoma el color es a menudo entre marrón y negro, dependiendo de la profundidad de la producción de la melanina a diferentes profundidades en la piel. Los descriptores de color son principalmente parámetros estadísticos calculados a partir de diferentes canales de color como el valor promedio y desviación estándar de RGB o HSV.

Diámetro

En la característica del diámetro se implementó una función que permite verificar los puntos extremos de la imagen para los dos ejes seguido de una función de la distancia entre dos puntos lo que me dará como resultado la distancia entre punto en cantidad de

píxeles, la distancia máxima que utilizaremos como indicador para ver si el lunar es mayor a 6mm es de 130 píxeles, esta proporción se halló gracias a la base de datos que se tiene, ya que todas las imágenes se encuentran clasificadas y son del mismo tamaño, además que algunas de ellas cuentan con una regla que miden el tamaño de cada lunar lo que permitió poder sacar la cantidad de píxeles que ocupan los 6 mm marcados por la regla en la imagen,

Se define el algoritmo utilizado para poder determinar los datos correspondientes al diámetro.

$$\begin{aligned} \text{Borde} &= \text{borde(imagen)} \\ \text{CoordX} &= \text{píxel}(x,y) \\ \text{CoordY} &= \text{píxel}(x,y) \end{aligned}$$

Donde:

$$\text{Diametro} = \begin{cases} \text{Si, } (x, y) > 6 \\ \text{No, } (x, y) \leq 6 \end{cases}$$

4.2.3. Red neuronal multicapa *backpropagation*

Para realizar las pruebas obtenidas del procesamiento de imágenes y de la extracción de características, fue necesario utilizar un clasificador que sea entrenado con toda la información obtenida y corroborar el grado de certeza del sistema implementado.

Utilizamos una red neuronal multicapa basándonos en el algoritmo de Backpropagation para su entrenamiento. Para el caso de las características extraídas con la regla ABCD se usó una red de una sola capa oculta de cinco neuronas y una capa de salida con una neurona en dicha capa.

4.3. Red neuronal convolucional

4.3.1. Diseño de la red

En las redes neuronales convolucionales diseñar el clasificador consiste en determinar su arquitectura, que es la forma en que sus componentes están conectados así como determinar los hiper parámetros, que son aquellos parámetros no entrenables, por lo tanto no cambian durante el aprendizaje del clasificador. El paradigma que se propone utilizar es el de aprendizaje supervisado, donde el clasificador tendrá las respuestas correctas por cada muestra que ingresa. Los pesos son ajustados de tal manera que la red pueda producir resultados que sean lo más cercanos posibles a las respuestas deseadas.

La arquitectura de una Red Convolucional tiene gran influencia en el rendimiento de los parámetros escogidos, sobrepasar el número de neuronas puede disminuir el nivel de generalización corriendo el riesgo de alcanzar un sobre ajuste en el aprendizaje. En cuanto a las capas estas tienen dos tareas en la red neuronal [Jia et al., 2014], la primera

denominada *forward pass* que toma las entradas y produce las salidas y el *backward pass* que toma la gradiente con respecto a la salida y calcula las gradientes con respecto a los parámetros y las entradas, estos cálculos son retornados a capas previas para repetir el proceso reiteradamente.

Para el presente trabajo de investigación se propone utilizar una red neuronal convolucional, que está basada en una arquitectura ligera y con resultados exitosos, red de modelo secuencial de 4 etapas

Se realiza en cada capa de la red la función de max pooling, el cual disminuye la cantidad de parámetros al quedarse con las características más comunes, La forma de reducir parámetros se realiza mediante la extracción de estadísticas como el promedio o el máximo de una región fija del mapa de características, al reducir características el método pierde precisión aunque mejora su compatibilidad. En la siguiente imagen 4.4 se muestra al arquitectura de la red.

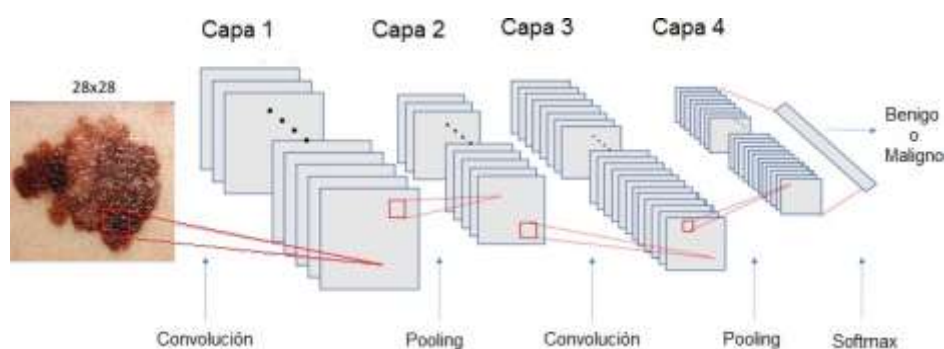


Figura 4.4: Modelo de arquitectura de red a utilizar.

4.3.2. Arquitectura del clasificador

El entrenamiento de una red neuronal se realiza por el algoritmo *backpropagation* y este puede ser realizado con uno de los siguientes métodos, según [Kimashev, 2017] el método estocástico, el método de lotes (batch) y el método mini lotes (mini-batch). Con el método estocástico, si se ha encontrado un incremento en el peso entonces inmediatamente se actualiza el peso, es decir, hay una actualización constante de pesos y la red neuronal aprende de manera rápida. Con el método batch el incremento de todos los pesos se acumula en la actual iteración, terminada la iteración se actualizan todos los pesos con el monto acumulado. El método mini-batch es una combinación de los dos métodos anteriores, todas las muestras de entrenamiento son divididas en grupos y por cada grupo se acumula el incremento de los pesos el cual es actualizado al terminar la iteración en el grupo.

Capítulo 5

Pruebas y resultados

En este capítulo se presenta las métricas de evaluación utilizadas, los experimentos realizados y los resultados obtenidos, seguidamente se plantea una discusión sobre los resultados.

5.1. Técnicas para la determinación de cáncer de piel

Los métodos escogidos para la determinación de cáncer de piel son: Regla ABCD y CNN. De aquí en adelante se presenta resultados obtenidos en base a ambos métodos.

La regla de ABCD, es la regla más utilizada por especialistas a nivel mundial y más estudiada por investigadores, lo que hace un buen complemento con el conocimiento empírico adquirido a través de los años, es por eso que es utilizada para determinar su efectividad. Esta técnica es utilizada como un extractor de características que serán clasificadas por una red neuronal de múltiples capas por medio del algoritmo *Back Propagation*.

Las arquitecturas de aprendizaje profundo tienen una fuerte dependencia hacia los datos entrenados y las características aprendidas no pueden transferirse para predecir datos diferentes a los datos entrenados [Li and Luo, 2016]. Una red neuronal convolucional (CNN) se conforma principalmente de kernels que se encargan de procesar cada imagen para la extracción de características, a su vez el comportamiento de una CNN se ve afectado por los valores de los hiperparámetros, estos influyen en los resultados de entrenamiento y predicción. Es por ello que a continuación se realizan los experimentos para alcanzar un resultado exitoso en el reconocimiento de cáncer de piel de imágenes digitales. La CNN extrae características mediante sus kernels de convolución, los cuales se encuentran en el funcionamiento propio de la red, a diferencia del método anterior no se puede caracterizar con un nombre propio a las características extraídas internamente por la red, por ejemplo, no sabemos cuál de los diferentes pesos de la red representan el atributo de asimetría, como si se puede saber en la regla ABCD, de igual manera para las otras características.

5.2. Proceso de evaluación

Para tener un estándar de comparación en cuanto al porcentaje verdadero de detección de lunares con cáncer o no y poder trabajar con diferentes propuestas, las imágenes

serán analizadas por un profesional y así obtener la cantidad de lunares cancerígenos y cuáles no.

El criterio de evaluación que ha sido empleado es la medida del rendimiento general mediante F-Score. Para lo cual se han calculado los verdaderos positivos (PV), falsos positivos (FP) y falsos negativos (FN) en cada una de las técnicas para cada uno de los lunares analizados de las bases de datos según las ecuaciones (5.1) y (5.2).

$$Precision = \frac{\text{positivos verdaderos}}{\text{positivos verdaderos} + FP} \quad (5.1)$$

$$Sensibilidad = \frac{\text{positivos verdaderos}}{\text{positivos verdaderos} + FN} \quad (5.2)$$

5.3. Base de datos

Se trabajará con dos bases de datos que cuentan con distintas características las cuales se detallan a continuación:

- **BD1:** Base de Datos ISIC obtenida The International Skin Imaging Collaboration, en cual se utilizaron 500 imágenes con medidas de 1022*767 píxeles, del cual 250 imágenes corresponde a lunares benignos y 250 corresponden a lunares malignos [Matas Crespi, 2018].
- **BD2:** Base de Datos PH2DataSet utilizadas por estudiantes paraguayos donde realizan un diagnóstico computarizado de lesiones de lunares usando la regla ABCD [Leguizam, 2015]. Su base de datos cuenta con 200 imágenes de tamaño 765*574 píxeles de los cuales 160 imágenes corresponden a lunares benignos y 40 corresponden lunares malignos.

Todas las imágenes fueron transformadas en relación a su tamaño para poder realizar un mejor procesamiento de imágenes, reduciendo el tamaño de estas a 256*192 píxeles.

Las imágenes fueron analizadas por el Dr. Engelber Ludwing Navarro Mejía, quien cursó la carrera de Medicina Universidad San Marcos con especialidad en Dermatología (de la Cátedra de Dermatología de la Universidad Nacional Federico Villareal), para definir el grado de certeza de nuestro sistema. Según su diagnóstico de las 160 imágenes de BD2 tuvo una coincidencia del 98 % y en el diagnóstico de las 456 imágenes de BD1 tuvo una coincidencia del 100 %.

Para realizar un buen entrenamiento de las redes convolucionales, es necesario tener una gran cantidad de imágenes, por eso es conveniente incrementar la BD, para así obtener una mayor precisión en los resultados. para lograr esto se utiliza la técnica *Data augmentation*.

5.3.1. Data augmentation

Data augmentation tiene la funcionalidad de incrementar la cantidad de imágenes de la base de datos, al aplicarle a cada imagen transformaciones diversas para hacerlas

distintas a la original. Esto implica aumentar el conjunto de datos cada vez que se ejecuta una época de entrenamiento, lo que ayudará a mejorar el entrenamiento de la red. También se ha demostrado que reduce el sobreajuste de las redes [Lee et al., 2017].

Debido al tamaño limitado del conjunto de imágenes de entrenamiento usadas para la calibración de los parámetros de la red, es que se realiza un *data augmentation* de manera artificial. Cada ejemplo de entrenamiento es perturbado al azar con diferentes funciones que muestran a continuación:

- *Rotación*: Rotación aleatoria con un ángulo muestreado uniformemente entre 0 y 360 grados, para explotar la simetría rotacional en las imágenes;
- *Traslación*: Desplazamiento aleatorio muestreado uniformemente entre -4 y 4 píxeles (relativo al tamaño de la imagen original) en las direcciones x e y . El tamaño del turno es limitado para garantizar que el objeto de interés permanezca en el centro de la imagen;
- *Voltear* : La imagen se voltea con una probabilidad de 0.5;
- *Ajuste de brillo*: Los valores de píxeles se ajustan por igual en los tres canales de colores por un parámetro x obtenido de una distribución gaussiana en el rango $[0,1]$.
- *Corte*: El mapeo o shearing desplaza cada punto en la dirección vertical en una cantidad proporcional a su distancia desde el borde de la imagen. Se debe tener en cuenta que la dirección no tiene que ser necesariamente vertical y puede ser arbitraria.
- *Zoom*: Esta transformación acerca o aleja la imagen inicial. El parámetro *zoomrange* controla el factor de zoom.
- *Rescala*: Esta Transformación cambia el tamaño de las imágenes aumentando o disminuyendo el largo y ancho de la imagen.

Obteniendo así una cantidad 91 200 nuevas imágenes de entrenamiento para la base de datos 1 y 32 000 imágenes para la base de datos 2, todo esto por cada época de entrenamiento.

5.4. Segmentación de lunares benignos y malignos

Para poder obtener un buen diagnóstico es importante realizar una buena segmentación, es así que utilizando ambas bases de datos (es decir ISIC, universidad de Asunción) se hicieron varias pruebas para los casos malignos y benignos, como se indica a continuación:

Para poder segmentar, se aplica sobre la imagen original un cambio de colores a grises, una vez aplicado eso se realiza el filtro gaussiano, luego se aplica un umbral que puede ser elegido de manera manual o de manera automático por medio del algoritmo de OTSU, para finalmente obtenemos la región binaria y substraemos de la imagen original para obtener la imagen segmentada. A continuación en la imagen 5.1 se muestra el caso de la segmentación de un lunar benigno correspondiente a la base de datos de ISIC.




Figura 5.1: Segmentación de lunar benigno.

En esta imagen podemos observar, que la segmentación se realiza de manera adecuada debido a la forma de lunar casi simétrica, así mismo se utilizó un umbral otsu de 136 que permite obtener en su totalidad el objetivo principal de estudio que es el lunar. De igual manera se realiza la segmentación con un lunar maligno correspondiente de la misma base de datos, la cual se muestra en la imagen 5.2 a continuación.




Figura 5.2: Segmentación de lunar maligno.

Se puede evidenciar que el proceso de segmentación no es tan efectivo, esto debido a la forma y apariencia del lunar, ya que la imagen cuenta con mayor ruido, sin borde definido para su segmentación total. Se utilizó un umbral otsu de 85 que permitió poder obtener la mayor parte del lunar.

De igual manera se realizaron pruebas con la base de datos de la Universidad de Paraguay tanto para lunares benignos como para lunares malignos. Identificación de segmentación de lunar benigno en base de datos Universidad de Asunción, según la imagen 5.3.




Figura 5.3: Segmentación de lunar benigno.

El resultado de segmentación obtenido de la imagen mostrada, es muy parecido al realizado con el lunar de la base de datos ISIC, segmenta el lunar casi en su totalidad, sin perder mucho de este, lo que es fundamental para el objetivo del análisis. En la prueba con lunares malignos se puede evidenciar en la imagen 5.4 que la segmentación mejora en comparación a la realizada con otra base de datos, si bien la segmentación realizada no es el ideal para el objetivo buscado, se puede identificar características que permitan obtener resultados mucho más precisos.




Figura 5.4: Segmentación de lunar maligno.

En base a las pruebas de segmentación realizadas con lunares benignos y malignos, evidenciamos que a la hora de evaluar los benignos es más eficiente que en caso de los malignos, debido a la forma que tiene el lunar maligno a diferencia del lunar benigno, se puede concluir que existe un patrón a la hora de segmentar estas dos lesiones, en la tabla 5.1 se muestra el resultado de la evaluación para ambas bases de datos.








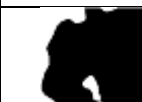





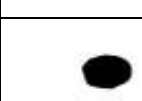

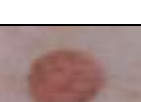








BD	TIPO	LUNAR	BINARIZADO	SEGMENTADO
PH2DATASET	BENIGNO1			
PH2DATASET	BENIGNO2			
PH2DATASET	MALIGNO1			
PH2DATASET	MALIGNO2			
ISIC	BENIGNO1			
ISIC	BENIGNO2			
ISIC	MALIGNO1			
ISIC	MALIGNO2			

Tabla 5.1: Segmentación de lunares malignos y benignos de ambas BD.

5.5. Extracción de características

Para poder obtener las características se determinó utilizar el método ABCD en base a los trabajos relacionados, ya que es el más conocido y utilizado por la eficiencia de los resultados obtenidos en otros trabajos y también porque la mayor cantidad de expertos en la materia (dermatólogos) aplican este método para sus diagnósticos.

Se implementaron distintas técnicas para determinar las diferentes características a analizar y así determinar las mejores para la Asimetría, Borde, Color y Diámetro. En base a los resultados obtenidos de las técnicas implementadas, se seleccionaron las que arrojaron un mayor índice de efectividad en base al análisis previo de los lunares por un

especialista de la materia, para la características de ABCD. A continuación se muestra el caso correspondiente a un lunar benigno y maligno respectivamente.

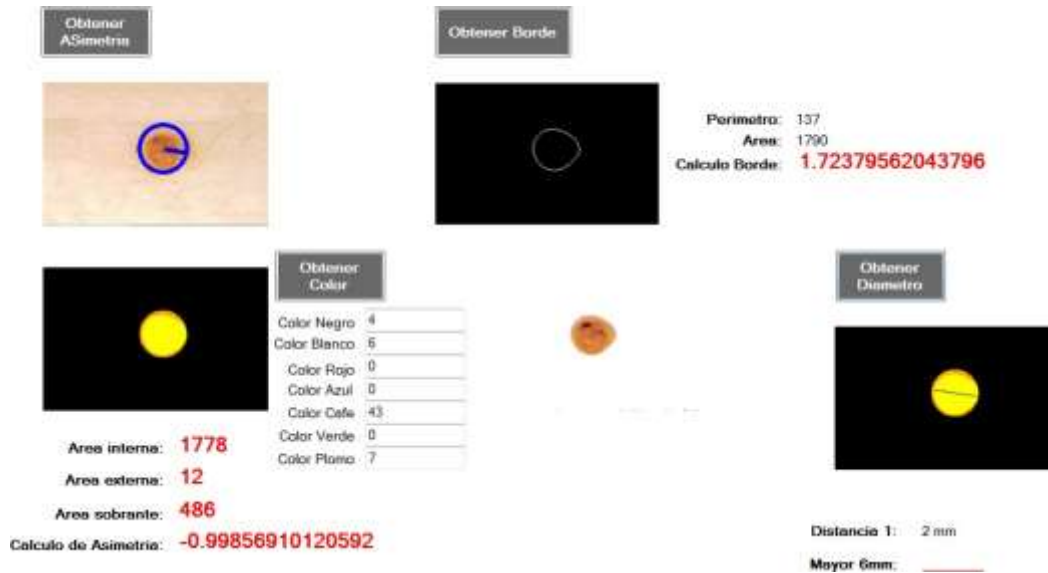


Figura 5.5: Extracción de características ABCD lunar benigno.

Características ABCD obtenidas de un lunar benigno mostradas en la figura 5.5 que a simple vista si realizamos la comparacion con la figura 5.6 que corresponde al lunar maligno la diferencia de resultados es grande.

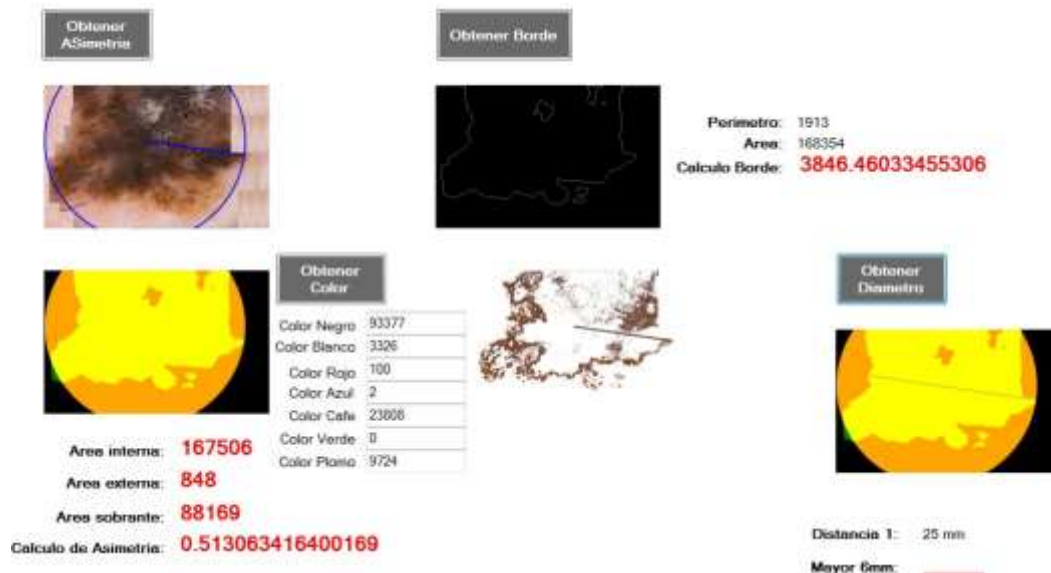


Figura 5.6: Extracción de características ABCD lunar maligno.

En estos dos casos, claramente se puede ver que los índices son distintos y se puede apreciar las diferencias entre uno y otro. Se puede concluir:

- Para el caso de la Asimetría se puede observar que se obtiene resultados positivos asociados a los lunares maligno y resultados negativos asociados a los lunar benignos.
- En la característica del borde, se identifica que para el resultado de borde regulares, los valores obtenidos aproximan más a cero, mientras el resultado se aleje de cero es un indicativo a que el borde sera irregular.
- Para el resultado del Color se definen siete tipos de colores: negro, blanco, rojo, azul, cafe, verde y plomo a mayor cantidad y variabilidad en la presencia de colores es indicativo para que el lunar sea maligno, para el caso de la cantidad de área ocupada en el lunar por color sea moderada y/o alta, entonces es indicativo para ser maligno, caso contrario benigno.
- Para el Diámetro se define el resultado en base al tamaño del lunar si este es mayor a 6mm es una característica para que el lunar sea maligno, caso contrario sea benigno.

En 5.2 se puede apreciar el patrón obtenido de la extracción de características en relación a las bases de datos utilizadas, donde los lunares benignos obtienen una puntuación baja en relación al borde, color y diámetro a diferencia de los malignos, respecto a la asimetría los benignos obtienen números negativos y los malignos positivos. En base a lo especificado podemos concluir como correcta la extracción de sus características debido a una diferencia marcada de los resultados de ambos tipos de lunares.

BD	LUNAR	ASIMETRIA	BORDE	C.NEGRO	C.BLANCO	C.ROJO	C.AZUL	C.CAFE	C.VERDE	C.PLOMO	DIAMETRO
PH2DATASET	BENIGNO	-0.97	11.61	473	0	0	0	101	0	0	3
PH2DATASET	BENIGNO	-1	2.49	0	0	0	0	24	0	0	4
PH2DATASET	BENIGNO	-0.99	7.54	826	255	0	0	0	0	35	4.5
PH2DATASET	MALIGNO	0.93	488.53	107	114	1022	0	504	0	4740	8
PH2DATASET	MALIGNO	0.96	525.24	6230	7	593	12	266	0	1556	7
PH2DATASET	MALIGNO	0.97	216.44	2539	119	41	0	1017	0	2282	7
ISIC	BENIGNO	-0.88	67.90	153	0	0	0	0	0	674	4
ISIC	BENIGNO	-1	3.18	25	0	0	0	336	0	10	3
ISIC	BENIGNO	-0.93	31.05	0	46	0	0	15	0	0	6
ISIC	MALIGNO	0.43	3252.70	35557	360	0	393	76	0	4847	17
ISIC	MALIGNO	1	3586.82	33134	100	297	0	21436	0	4849	10
ISIC	MALIGNO	0.38	862.03	36894	112	0	1538	6169	0	7210	12

Tabla 5.2: Características ABCD de lunares malignos y benignos de ambas BD.

Como se comentó anteriormente las características mencionadas anteriormente, es decir asimetría, borde, color y diámetro no son apreciadas en una CCN las cuales se encuentran en sus matrices de convolución.

5.6. Arquitectura utilizada

El método mini-batch presenta mejores resultados que los otros dos métodos, esto fue demostrado con el entrenamiento del conjunto de datos MNIST realizado por [Galarza Bravo and Flores Calero, 2018], donde el promedio de la función de pérdida del método mini-batch es menor que en los otros métodos. Es así que se ha decidido usar este método para el entrenamiento de la CNN que se utilizará en el presente proyecto.

El modelo simplificado de entrenamiento de una red neuronal convolucional se describe a continuación:

- Se utiliza un modelo secuencial.
- Capas de convoluciones de 32, 64, 128 y 256.
- Se utiliza la función RELU..
- Se usa Max pooling con filtro de 2*2.

Modelo CNN 4




Figura 5.7: Arquitectura utilizada para la red convolucional.

Es importante mencionar que existen modelos pre entrenados para aplicaciones de reconocimiento de imágenes, pero dichas redes no fueron útiles para la presente tesis, por ser imágenes totalmente diferentes a las de dermatología, en ese sentido fue mejor entrenar una red de forma completa.

5.7. Resultados

Se realizaron distintas pruebas para así poder identificar la arquitectura apropiada y de cuál de ellas obtendríamos un mayor nivel de precisión, dentro de las pruebas utilizamos mostramos las siguientes:

Modelo CNN 1



Figura 5.8: Modelo 1 de CNN.

En este modelo se utilizaron 4 capas, distribuidas en dos capas con 32 neuronas y las dos capas siguientes con una cantidad de 64 neuronas cada una.


Modelo CNN 2

Figura 5.9: Modelo 2 de CNN.

El modelo 2 se mantiene la estructura de las 4 capas utilizadas, pero sufre un cambio correspondiente a las cantidad de neuronas por capa, se utilizan 3 capas con 32 neuronas cada una y la última capa con 64 neuronas.

Modelo CNN 3

Figura 5.10: Modelo 3 de CNN.

Al identificar que las estructuras anteriores no generaba un cambio mayor positivo en base a los resultados es que se optó por aumentar una capa más a diferencia de las dos anteriores, usando entonces 5 capas las cuales 3 de ellas con 32 neuronas y las dos últimas capas con 64 neuronas. A pesar del cambio realizado en la estructura no se bien mejora alguna.

Es así que para poder lograr el porcentaje deseado de precisión de un 97 %, se realizaron varias pruebas para así encontrar la arquitectura adecuada de la red convolucional, utilizando como las 4 primeras capas Conv2D que trabajaran con las imágenes de entradas que se ven como matrices bidimensionales, 32 en la primera capa, 64 en la segunda capa, 128 en la tercera capa y 256 en la cuarta capa, que en realidad son el número de nodos en cada capa. Respecto a la función de activación que utilizaremos para nuestras 4 capas es la función RELU o activación lineal rectificadora, que transforma los valores introducidos, anulando los valores negativos y dejando los positivos tal y como entran, así mismo se ha comprobado que esta función, trabaja bien con redes neuronales. Una vez que se tienen los valores positivos aplicamos la función MaxPooling2D que es una ventana móvil a través de un espacio de entrada 2D, donde el valor máximo dentro de esa ventana es la salida. En la figura 5.11 se ejemplifica la arquitectura de la red para una mejor comprensión.

Modelo CNN 4




Figura 5.11: Arquitectura utilizada para la red convolucional.

A continuación en 5.3 la comparación entre los diferentes modelos para diferentes arquitecturas y parámetros CNN, donde el último valor de precisión del 96 % corresponde a la arquitectura indicada líneas anteriores:

Técnica	Precisión
Modelo CNN 1	87 %
Modelo CNN 2	90 %
Modelo CNN 3	93 %
Modelo CNN 4	97 %

Tabla 5.3: Tabla de resultados de precisión de modelos CNN.

En base a la determinación de la estructura ideal para obtener un mayor porcentaje de efectividad es que se realizaron las pruebas en comparación del método ABCD contra la CNN utilizando ambas bases de datos. Los resultados de las pruebas son las siguientes:

Base de Datos: PH2Dataset

Técnicas: ABCD vs Modelo 1 CNN

Técnica	Precisión	Sensibilidad	Especificidad
ABCD	91 %	96 %	90 %
CNN	87 %	89 %	89 %

Tabla 5.4: Comparación de los resultados entre la regla ABCD y modelo 1 CNN para la base de datos PH2Dataset.

Base de Datos: ISIC

Técnicas: ABCD vs Modelo 1 CNN

Técnica	Precisión	Sensibilidad	Especificidad
ABCD	91 %	96 %	90 %
CNN	88 %	91 %	90 %

Tabla 5.5: Comparación de los resultados entre la regla ABCD y modelo 1 CNN para la base de datos ISIC.

Base de Datos: PH2Dataset

Técnicas: ABCD vs Modelo 2 CNN

Técnica	Precisión	Sensibilidad	Especificidad
ABCD	91 %	96 %	90 %
CNN	90 %	96 %	92 %

Tabla 5.6: Comparación de los resultados entre la regla ABCD y modelo 2 CNN para la base de datos PH2Dataset.

Base de Datos: ISIC

Técnicas: ABCD vs Modelo 2 CNN

Técnica	Precisión	Sensibilidad	Especificidad
ABCD	91 %	96 %	90 %
CNN	90 %	96 %	93 %

Tabla 5.7: Comparación de los resultados entre la regla ABCD y modelo 2 CNN para la base de datos ISIC.

Base de Datos: PH2Dataset

Técnicas: ABCD vs Modelo 3 CNN

Técnica	Precisión	Sensibilidad	Especificidad
ABCD	91 %	96 %	90 %
CNN	93 %	95 %	91 %

Tabla 5.8: Comparación de los resultados entre la regla ABCD y modelo 3 CNN para la base de datos PH2Dataset.

Base de Datos: ISIC

Técnicas: ABCD vs Modelo 3 CNN

Técnica	Precisión	Sensibilidad	Especificidad
ABCD	91 %	96 %	90 %
CNN	93 %	96 %	93 %

Tabla 5.9: Comparación de los resultados entre la regla ABCD y modelo 3 CNN para la base de datos ISIC.

A continuación la siguiente prueba fue la más óptima y que mejora el trabajo realizado por los estudiantes Paraguayos en su investigación utilizando la regla ABCD.

Base de Datos: PH2Dataset

Técnicas: ABCD vs Modelo 4 CNN

Técnica	Precisión	Sensibilidad	Especificidad
ABCD	91 %	96 %	90 %
CNN	95 %	97 %	92 %

Tabla 5.10: Comparación de los resultados entre la regla ABCD y CNN para la base de datos PH2Dataset.

A continuación podemos apreciar la curva ROC del modelo CNN, donde la línea punteada es la referencia y la línea azul la curva respectiva:




Figura 5.12: Curva ROC para la precisión de la red CNN para la base de datos PH2Dataset.

Base de Datos: ISIC

Técnicas: ABCD vs Modelo 4 CNN

Técnica	Precisión	Sensibilidad	Especificidad
ABCD	91 %	96 %	90 %
CNN	97 %	98 %	92 %

Tabla 5.11: Comparación de los resultados entre la regla ABCD y CNN para la base de datos ISIC.

A continuación en la figura 5.7 podemos apreciar la curva ROC del modelo CNN, donde la línea punteada es la referencia y la línea azul la curva respectiva:

En base a los resultados obtenidos de acuerdo a las bases de datos utilizadas, podemos concluir que al utilizar la BD de la universidad de Asunción PH2Dataset, la CNN se impone con un resultado de un 94 % de precisión ante un 90 % de precisión de la ABCD, de igual manera al utilizar la BD de ISIC da un resultado de un 97 % de precisión de la CNN contra un 91 % de precisión de la ABCD utilizando el modelo 4 para la CNN, por




Figura 5.13: Curva ROC para la precisión de la red CNN para la base de datos ISIC.

lo que de esta manera se logra demostrar la efectividad de la CNN a la hora de trabajar con imágenes digitales y procesarlas.

Se puede apreciar que el resultado con una BD es mejor a diferencia de otra debido a que una cuenta con mayor cantidad de imágenes a ser evaluadas.

Capítulo 6

Conclusiones y Trabajos Futuros

En esta sección presentaremos las conclusiones de la presente tesis así como las mejoras o trabajos que aún se pueden realizar y que mejorarían los resultados de la tesis.

6.1. Conclusiones

Los resultados obtenidos demuestran que se puede implementar estructuras de redes convolucionales que permitan analizar el diagnóstico de cáncer de piel, así mediante la comparación poder identificar cual de ellas es la más eficiente a la hora de brindar un diagnóstico inicial de un lunar maligno o benigno.

El hecho de contar con varias arquitecturas de redes convolucionales nos permite identificar poco a poco cual de estas trabaja mejor en base a los resultados obtenidos para el diagnóstico de lunares cancerígenos.

El adelanto constante de la tecnología ayuda a distintas áreas de la medicina, dentro de ellas el cáncer de piel. Es así que apareció la técnica ABCD y que en la actualidad es la técnica más utilizada por los profesionales de la piel, pero también influye la tecnología y eso hace que los resultados mejoren día a día, el cual se ha demostrado al utilizar las redes convolucionales y realizar la comparación con la técnica ABCD que nos permitió identificar la eficiencia de las redes convolucionales sobre la técnica ABCD y esto debido a que en comparación a los trabajos relacionados analizados, el trabajo en [Alcón et al., 2009] presenta una precisión del 94 %, si bien presenta una base de datos validada Dermnet, solo utiliza 152 imágenes para poder realizar sus pruebas, lo que hace que la el entrenamiento no sea el más óptimo para la gran cantidad de casos de lunares malignos que existen en el mundo. asimismo para la característica del color determina valores fijos para los colores blanco, rojo, café, marrón, azul y negro que le permitieran encontrar regiones que contengan tonalidades de ese color en base a los vecinos más cercanos y aún así con las redes convolucionales se obtuvo un mejor desempeño.

Es posible diagnosticar el cáncer de piel a partir de una imagen digital, usando redes neuronales convolucionales se llegó a una precisión del 97 % de acierto lo que demuestra que el uso de este tipo de técnicas se vuelve promisorias como sistemas de diagnóstico. Cabe mencionar que el método tradicional más utilizado ABCD también fue implementado en la presente tesis, llegando a una precisión del 91 % con la misma base de datos, así como también se realizó la prueba usando la base de datos de los estudiantes para-

guayos [Leguizam, 2015] que en su estudio obtuvieron una precisión del 90.63 % contra un 91 % usando el metodo ABCD y un 95 % usando la red convolucional desarrolladas en la presente tesis, corroborando el buen desempeño de las redes convolucionales. Además es importante notar que estos métodos tradicionales que siguen la regla ABCD detallan cuatro características que permite un diagnóstico que supera el 90 % y que brinda resultados óptimos, pero que a su vez la redes convolucionales utilizan una mayor cantidad de características lo que nos permite aún tener un mayor grado de certeza en sus resultados, que al solo utilizar las cuatro características del ABCD.

El preprocesamiento de las imágenes es de suma importancia en el método ABCD, ya que una mala segmentación llevaría a diagnósticos errados, ya que dicho método depende de factores morfológicos de la lesión, esto a diferencia de la red convolucional no necesita una previa segmentación o una buena determinación de la región de la lesión, pudiendo usarse las imágenes de forma directa del dermatoscopio como se utilizó en la presente tesis. Además, podemos decir que el uso de redes convolucionales ayudará a mejorar el proceso de diagnóstico en cuanto se tenga mayor variabilidad de casos que no sigan la regla ABCD, es conocido que en las enfermedades no siempre se manifiestan todos los síntomas mas aparecen algunos nuevos que a veces no son considerados por los especialistas, en el modelo propuesto de redes convolucionales solo se necesita tener las imágenes de las lesiones que quizás no cumplan con la regla ABCD pero la propuesta si podrá diagnosticarla si se entrenó con casos semejantes esto la hace más robusta al necesitar una base de datos amplia en los diferentes casos que puedan existir.

En redes convolucionales encontrar la mejor combinación de hiper parámetros y el análisis de la influencia del tamaño del kernel en las convoluciones son determinantes en el éxito o fracaso del reconocimiento, además los diferentes tipos de funciones de activación también influyen los resultados. Para la presente tesis, se probaron varios modelos con kernels de convolución de dimensión 3x3 con funciones de activación RELU, variando la cantidad de capas las cuales fueron presentadas en el capítulo anterior donde se tenía el Modelo 1, Modelo 2, Modelo 3 y Modelo 4, obteniendo resultados de 87 %, 90 %, 93 % y 97% de acierto respectivamente donde se llevo a concluir que para el problema planteado el Modelo 4 fue el mejor obteniendo la mayor precisión.

La extracción de características mediante la regla ABCD, fue implementada siguiendo los lineamientos de los especialistas donde: la asimetría, el borde, el color los cuales son atributos subjetivos, incluso para los mismos especialistas existe una confusión al momento de realizar el diagnóstico, mientras que el diámetro es una medida directa de la resolución de la imagen. En ese sentido se usaron diferentes métricas para cuantificar dichos atributos usando los que mejor cuantifican dichas características, cabe mencionar que en la presente tesis en su inicio se consultó con médico especialista en dermatología que observó algunas imágenes de las bases de datos ya clasificadas esto ratifica que es importante contar con una base de datos validada con las biopsias de diagnóstico para que la red será entrenada de forma adecuada y dará resultados robustos.

Es importante notar que, si se tienen buenas características, la etapa de clasificación no es muy complicada, se usó una red de una sola capa escondida y con el algoritmo back-propagation sería suficiente para la clasificación se pueden usar diferentes clasificadores, pero los resultados serían similares. Esto ratifica que la regla ABCD podría ser mejorada como se ve en la literatura donde incrementan algunas características adicionales, pero se necesitaría otros factores como la evolución de la lesión sin embargo creemos que el uso de las redes convolucionales ya usa más características y es por eso que presentan mejores

resultados que el método ABCD

También es importante resaltar que el uso de redes convolucionales no necesita preprocesamiento de la imagen, que la propuesta sea robusta ante los diferentes problemas como ruido, en muchos casos el color de la piel no favorece al diagnóstico, así como la presencia de vellos como se aprecia en varias de las imágenes usadas, además, variaciones de iluminación y resolución que son dependientes del dispositivo ya sea por antigüedad deteriorándose por el tiempo dificultaran una adecuada extracción. De nuevo podemos afirmar que el modelo propuesto minimizará los errores de los problemas anteriormente mencionados.

6.2. Trabajos Futuros

- Siendo la red convolucional entrenada con una base de datos limitada y además de usar técnicas de aumentación de datos y dada la efectividad conseguida en la presente tesis con seguridad los resultados mejorarían si la base de datos de imágenes aumentara considerablemente, por eso un trabajo futuro es buscar mas bases de datos dermatológicas de melanomas, para validar y mejorar la performance de los resultados.
- Otro punto importante es que la tecnología ha hecho que los dispositivos móviles posean mejores cámaras fotográficas y si se realiza un buen enfoque, una buena resolución e iluminación se podrán obtener imágenes digitales de lesiones de piel y probar el modelo propuesto con dichas imágenes por eso realizar eso como trabajo futuro ampliaría la aplicabilidad de la propuesta.
- El sistema que se desarrollo presenta una interfaz para el apoyo al diagnóstico de lesiones de piel, el cual podría ser desarrollado en un ambiente web para poder ampliar su aplicabilidad además de poder ayudar a capturar nuevas imágenes.
- La gran mayoría de especialistas continuan utilizando el método ABCD para su diagnostico,acompañado de la la experiencia que les permite identificar y diferenciar de un lunar benigno con un maligno, a pesar de que aún existe un margen de error a la hora de evaluación visual, es así que sería recomendable incluir software como soporte de ayuda para asi obtener un diagnóstico con mayor precisión.

Bibliografía

- [Abbas et al., 2011] Abbas, Q., Celebi, M. E., Fondón García, I., and Rashid, M. (2011). Lesion border detection in dermoscopy images using dynamic programming. *Skin Research and Technology*, 17(1):91–100.
- [Abbas et al., 2013] Abbas, Q., Celebi, M. E., Serrano, C., García, I. F., and Ma, G. (2013). Pattern classification of dermoscopy images: A perceptually uniform model. *Pattern Recognition*, 46(1):86–97.
- [Alcón et al., 2009] Alcón, J. F., Ciuhu, C., Ten Kate, W., Heinrich, A., Uzunbajakava, N., Krekels, G., Siem, D., and De Haan, G. (2009). Automatic imaging system with decision support for inspection of pigmented skin lesions and melanoma diagnosis. *IEEE journal of selected topics in signal processing*, 3(1):14–25.
- [ANEXO et al., 2018] ANEXO, N., DE LA TÉCNICA, P. D. A., and DE REEDUCACIÓN, P. G. (2018). Efectos de la reeducación postural global sobre fuerza muscular respiratoria y expansión torácica en pacientes con cáncer gástrico. page 114.
- [Anibal, 2010] Anibal, B. R. (2010). La informática aplicada a la medicina. *American Cancer Society*, page 12.
- [Argenziano et al., 2003] Argenziano, G., Soyer, H. P., Chimenti, S., Talamini, R., Corona, R., Sera, F., Binder, M., Cerroni, L., De Rosa, G., Ferrara, G., et al. (2003). Dermoscopy of pigmented skin lesions: results of a consensus meeting via the internet. *Journal of the American Academy of Dermatology*, 48(5):679–693.
- [Armstrong et al., 2007] Armstrong, B. K., Gillespie, J. A., Leeder, S. R., Rubin, G. L., and Russell, L. M. (2007). Challenges in health and health care for australia. *Medical Journal of Australia*, 187(9):485.
- [Badrinarayanan et al., 2017] Badrinarayanan, V., Kendall, A., and Cipolla, R. (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 39(12):2481–2495.
- [Barata et al., 2014] Barata, C., Ruela, M., Francisco, M., Mendonça, T., and Marques, J. S. (2014). Two systems for the detection of melanomas in dermoscopy images using texture and color features. *IEEE Systems Journal*, 8(3):965–979.
- [Bendezú-Sarcines et al., 2017] Bendezú-Sarcines, C. E., Oscco-Torres, O., and Anyarín-Simón, E. (2017). El conocimiento y medidas preventivas sobre neoplasia mamaria en usuarias de un centro de salud ica, peru 2010. *Revista Médica Panacea*, 2(1).

- [Benvenuto-Andrade et al., 2007] Benvenuto-Andrade, C., Dusza, S. W., Agero, A. L. C., Scope, A., Rajadhyaksha, M., Halpern, A. C., and Marghoob, A. A. (2007). Differences between polarized light dermoscopy and immersion contact dermoscopy for the evaluation of skin lesions. *Archives of dermatology*, 143(3):329–338.
- [Brinker et al., 2019] Brinker, T. J., Hekler, A., Enk, A. H., and von Kalle, C. (2019). Enhanced classifier training to improve precision of a convolutional neural network to identify images of skin lesions. *PloS one*, 14(6).
- [cancer de mama y yo, 2012] cancer de mama y yo, E. (2012). <http://elcancerdemamayyo.com/tocate-una-muestra-de-amor-que-empieza-en-la-adolescencia/pulseras-i-love-bobbles/>.
- [Cañedo Andalia et al., 2005] Cañedo Andalia, R., Ramos Ochoa, R. E., and Guerrero Pupo, J. C. (2005). La informática, la computación y la ciencia de la información: una alianza para el desarrollo. *Acimed*, 13(5):1–1.
- [Canny, 1986] Canny, J. (1986). A computational approach to edge detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, (6):679–698.
- [Capdehourat et al., 2011] Capdehourat, G., Corez, A., Bazzano, A., Alonso, R., and Musé, P. (2011). Toward a combined tool to assist dermatologists in melanoma detection from dermoscopic images of pigmented skin lesions. *Pattern Recognition Letters*, 32(16):2187–2196.
- [Capdehourat et al., 2009] Capdehourat, G., Corez, A., Bazzano, A., and Musé, P. (2009). Pigmented skin lesions classification using dermatoscopic images. In *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*, pages 537–544. Springer.
- [Cardenas et al., 2018] Cardenas, F. d. J. N., Chi, I. D. C. Z., Redondo, A. M. F., Hernández, J. M., et al. (2018). Aplicación de técnicas de minería de datos para la tipificación de enfermedades cardiovasculares en alumnos universitarios. *Ciencia Huasteca Boletín Científico de la Escuela Superior de Huejutla*, 6(11).
- [Celebi and Aslandogan, 2005] Celebi, M. E. and Aslandogan, Y. A. (2005). A comparative study of three moment-based shape descriptors. In *Information Technology: Coding and Computing, 2005. ITCC 2005. International Conference on*, volume 1, pages 788–793. IEEE.
- [Correa et al.,] Correa, D. N. L., Paniagua, L. R. B., Noguera, J. L. V., Pinto-Roa, D. P., and Toledo, L. A. S. Computerized diagnosis of melanocytic lesions based on the abcd method.
- [Daignostrum, 2017] Daignostrum (2017). Investigadores crean algoritmo para la detección visual del cáncer de piel.
- [Erkol et al., 2005] Erkol, B., Moss, R. H., Joe Stanley, R., Stoecker, W. V., and Hvatum, E. (2005). Automatic lesion boundary detection in dermoscopy images using gradient vector flow snakes. *Skin Research and Technology*, 11(1):17–26.

- [Esteva et al., 2017] Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., and Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639):115.
- [Feng et al., 2013] Feng, J., Isern, N. G., Burton, S. D., and Hu, J. Z. (2013). Studies of secondary melanoma on c57bl/6j mouse liver using 1h nmr metabolomics. *Metabolites*, 3(4):1011–1035.
- [Ferlay et al., 2016] Ferlay, J., Soerjomataram, I., Dikshit, R., Eser, S., Mathers, C., Rebelo, M., Parkin, D. M., Forman, D., and Bray, F. (2016). Cancer incidence and mortality worldwide: sources, methods and major patterns in globocan 2012. *International journal of cancer*, 136(5):E359–E386.
- [Fornaciali et al., 2014] Fornaciali, M., Avila, S., Carvalho, M., and Valle, E. (2014). Statistical learning approach for robust melanoma screening. In *2014 27th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, pages 319–326. IEEE.
- [Fransen et al., 2012] Fransen, M., Karahalios, A., Sharma, N., English, D. R., Giles, G. G., and Sinclair, R. D. (2012). Non-melanoma skin cancer in australia. *Med J Aust*, 197(10):565–8.
- [Galarza Bravo and Flores Calero, 2018] Galarza Bravo, M. and Flores Calero, M. (2018). Pedestrian detection at night by using faster r-cnn y infrared images. *Ingenius. Revista de Ciencia y Tecnología*, (20):48–57.
- [Galvez, 2016] Galvez, F. (2016). Aplicaciones móviles permitirán futura detección temprana del cáncer de piel.
- [Ganster et al., 2001] Ganster, H., Pinz, P., Rohrer, R., Wildling, E., Binder, M., and Kittler, H. (2001). Automated melanoma recognition. *IEEE transactions on medical imaging*, 20(3):233–239.
- [García Jiménez et al., 2018] García Jiménez, R. et al. (2018). Mejora del rendimiento de redes convolucionales entrenadas para el reconocimiento de escena mediante el uso de información sobre los objetos comunes a éstas. Master’s thesis.
- [García Ferrando, 2017] García Ferrando, G. A. (2017). Deep learning en segmentación de imagen médica.
- [Ghahramani, 2015] Ghahramani, Z. (2015). Probabilistic machine learning and artificial intelligence. *Nature*, 521(7553):452.
- [Goodfellow et al., 2016] Goodfellow, I., Bengio, Y., Courville, A., and Bengio, Y. (2016). *Deep learning*, volume 1. MIT press Cambridge.
- [Guo et al., 2017] Guo, T., Dong, J., Li, H., and Gao, Y. (2017). Simple convolutional neural network on image classification. In *2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA)*, pages 721–724. IEEE.
- [Iyatomi et al., 2008] Iyatomi, H., Oka, H., Hashimoto, M., Tanaka, M., and Ogawa, K. (2008). An internet-based melanoma diagnostic system-toward the practical application. In *Computational Intelligence in Bioinformatics and Computational Biology, 2005qazZ. CIBCB’05. Proceedings of the 2005 IEEE Symposium on*, pages 1–4. IEEE.

- [Jerant et al., 2000] Jerant, A. F., Johnson, J. T., Demastes Sheridan, C., and Caffrey, T. J. (2000). Early detection and treatment of skin cancer. *American family physician*, 62(2).
- [Jia et al., 2014] Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., Guadarrama, S., and Darrell, T. (2014). Caffe: Convolutional architecture for fast feature embedding. In *Proceedings of the 22nd ACM international conference on Multimedia*, pages 675–678. ACM.
- [Jiménez and Israel, 2019] Jiménez, M. and Israel, J. (2019). Detección de tumores cutáneos malignos y benignos usando una red neuronal convolucional. B.S. thesis, Quito, 2019.
- [Kamangar et al., 2006] Kamangar, F., Dores, G. M., and Anderson, W. F. (2006). Patterns of cancer incidence, mortality, and prevalence across five continents: defining priorities to reduce cancer disparities in different geographic regions of the world. *Journal of clinical oncology*, 24(14):2137–2150.
- [Kaur et al., 2015] Kaur, R., Albano, P. P., Cole, J. G., Hagerty, J., LeAnder, R. W., Moss, R. H., and Stoecker, W. V. (2015). Real-time supervised detection of pink areas in dermoscopic images of melanoma: importance of color shades, texture and location. *Skin Research and Technology*, 21(4):466–473.
- [Kendall et al., 2015] Kendall, A., Grimes, M., and Cipolla, R. (2015). PoseNet: A convolutional network for real-time 6-dof camera relocalization. In *Proceedings of the IEEE international conference on computer vision*, pages 2938–2946.
- [Kimashev, 2017] Kimashev, A. (2017). Deep learning for text data mining: Solving spreadsheet data classification. Master’s thesis, University of Stavanger, Norway.
- [Koné and Boulmane, 2018] Koné, I. and Boulmane, L. (2018). Hierarchical resnext models for breast cancer histology image classification. In *International Conference Image Analysis and Recognition*, pages 796–803. Springer.
- [Lavanderos et al., 2018] Lavanderos, J., Pérez, J. A., Jeria, S., and Concha, D. (2018). Actualizaciones en melanoma maligno cutáneo. *Cuadernos De Cirugía*, 24(1):47–56.
- [Lee et al., 2017] Lee, J.-G., Jun, S., Cho, Y.-W., Lee, H., Kim, G. B., Seo, J. B., and Kim, N. (2017). Deep learning in medical imaging: general overview. *Korean journal of radiology*, 18(4):570–584.
- [Leguizam, 2015] Leguizam, D. (2015). Computerized diagnosis of melanocytic lesions based on the abcd method. In *Latin American Computing Conference (CLEI)*, pages 1–5.
- [Li and Luo, 2016] Li, L. and Luo, Y. (2016). Improved video moving target tracking based on camshift. *American Journal of Computational Mathematics*, 6(04):357.
- [López Silva et al., 2006] López Silva, S. M., Cordo, M., Sendra, J., Viera, A., and Santana, A. (2006). Diferenciación de piel sana y lesiones cutáneas pigmentadas mediante espectroscopía de reflectancia óptica difusa.

- [Maglogiannis et al., 2006] Maglogiannis, I., Zafiroopoulos, E., and Kyranoudis, C. (2006). Intelligent segmentation and classification of pigmented skin lesions in dermatological images. In *Hellenic Conference on Artificial Intelligence*, pages 214–223. Springer.
- [Manuel, 2013] Manuel, A. M. (2013). La mayoría de aplicaciones para detectar cáncer de piel son un timo, dicen los dermatólogos. *Dermatólogos del Centro Médico de la Universidad de Pittsburgh*.
- [Martin, 2002] Martin, M. (2002). Técnicas clásicas de segmentación de imagen. page 23.
- [Martín López, 2018] Martín López, M. (2018). Control de acceso basado en reconocimiento facial. page 41.
- [Martínez Llamas, 2018] Martínez Llamas, J. (2018). Reconocimiento de imágenes mediante redes neuronales convolucionales. page 57.
- [Martínez Martínez, 2014] Martínez Martínez, Á. (2014). Clasificación de imágenes dermatoscópicas.
- [Matas Crespi, 2018] Matas Crespi, A. (2018). Diseño de una aplicación para el tratamiento de imágenes dermatoscópicas. B.S. thesis, Universitat Politècnica de Catalunya.
- [Matich, 2001] Matich, D. J. (2001). Redes neuronales: Conceptos básicos y aplicaciones. *Universidad Tecnológica Nacional, México*.
- [Menzies et al., 1996] Menzies, S., Ingvar, C., and McCarthy, W. (1996). A sensitivity and specificity analysis of the surface microscopy features of invasive melanoma. *Melanoma research*, 6(1):55–62.
- [Menzies et al., 2003] Menzies, S. W., Crotty, K. A., Ingvar, C., and McCarthy, W. H. (2003). *An atlas of surface microscopy of pigmented skin lesions: dermoscopy*. McGraw-Hill Sydney, Australia.
- [Mera-González et al., 2014] Mera-González, L. Y., Delgado-Atencio, J. A., Valdiviezo-Navarro, J. C., and Cunill-Rodríguez, M. (2014). An algorithm for the characterization of digital images of pigmented lesions of human skin. In *Applications of Digital Image Processing XXXVII*, volume 9217, page 921718. International Society for Optics and Photonics.
- [Moya, 2012] Moya, J. P. A. (2012). Procesamiento y análisis de imágenes digitales. *libro electrónico disponible en [www. ie. itcr. ac. cr/palvarado/PAID/paid. pdf](http://www.ie.itcr.ac.cr/palvarado/PAID/paid.pdf) [consultada el 17 de julio de 2012]*.
- [Nachbar et al., 1994] Nachbar, F., Stolz, W., Merkle, T., Cognetta, A. B., Vogt, T., Landthaler, M., Bilek, P., Braun-Falco, O., and Plewig, G. (1994). The abcd rule of dermoscopy: high prospective value in the diagnosis of doubtful melanocytic skin lesions. *Journal of the American Academy of Dermatology*, 30(4):551–559.
- [Nugroho et al., 2019] Nugroho, A. A., Slamet, I., and Sugiyanto (2019). Skins cancer identification system of ham10000 skin cancer dataset using convolutional neural network. In *AIP Conference Proceedings*, volume 2202, page 020039. AIP Publishing LLC.

- [Ortega et al., 2012] Ortega, B. C., Garay, U. Á., and Gómez, G. (2012). Claves dermatoscópicas del melanoma acral lentiginoso. *Dermatología Revista Mexicana*, 56(3):180–186.
- [Otsu, 1975] Otsu, N. (1975). A threshold selection method from gray-level histograms. *Automatica*, 11(285-296):23–27.
- [Palacios-Martínez and D´iaz-Alonso, 2017] Palacios-Martínez, D. and D´iaz-Alonso, R. (2017). Dermatoscopia para principiantes (ii): estructuras dermatoscópicas y métodos diagnósticos. *SEMERGEN-Medicina de Familia*, 43(4):312–317.
- [Palmer Pol and Montaña Moreno, 1999] Palmer Pol, A. and Montaña Moreno, J. (1999). ¿ qué son las redes neuronales artificiales? aplicaciones realizadas en el ámbito de las adicciones. *Adicciones*, 11(3).
- [Picazo Montoya, 2018] Picazo Montoya, Ó. (2018). *Redes neuronales convolucionales profundas para el reconocimiento de emociones en imágenes*. PhD thesis, ETSI_Informatica.
- [Pérez, 2018] Pérez, R. R. C. (2018). *Reconocimiento de patrones en imágenes no dermatoscópicas para la detección de enfermedades malignas en la piel, utilizando redes neuronales convolutivas y autocodificadores*. PhD thesis, Universidad Nacional de San Agustín.
- [Quintero et al., 2018] Quintero, C., Merchán, F., Cornejo, A., and Galán, J. S. (2018). Uso de redes neuronales convolucionales para el reconocimiento automático de imágenes de macroinvertebrados para el biomonitorio participativo. *KnE Engineering*, 3(1):585–596.
- [Rezvantalab et al., 2018] Rezvantalab, A., Safigholi, H., and Karimijeshni, S. (2018). Dermatologist level dermoscopy skin cancer classification using different deep learning convolutional neural networks algorithms. *arXiv preprint arXiv:1810.10348*.
- [Rivero, 2012] Rivero, E. (2012). Doctor mole aplicación para detectar lunares cancerosos.
- [Rodríguez Saa et al., 2017] Rodríguez Saa, S., Peralta, R., Salerni, G., Cohen Sabban, E. N., and Cabo, H. A. (2017). Dermatoscopia del melanoma extensivo superficial. *Dermatología Argentina*, 23(3):154–156.
- [Roldán-Marín et al., 2013] Roldán-Marín, R., González-Álvarez, T., and Carrera, C. (2013). Diagnóstico del carcinoma basocelular mediante dermatoscopia y otras técnicas no invasivas. *Piel*.
- [Rosendahl et al., 2012] Rosendahl, C., Cameron, A., McColl, I., Wilkinson, D., et al. (2012). Dermatoscopy in routine practice: 'chaos and clues'. *Australian Family Physician*, 41(7):482.
- [Saez Contreras et al., 2018] Saez Contreras, Á. et al. (2018). Segmentación semántica para imágenes fisheye basada en cnn. page 160.
- [Scharcanski and Celebi, 2013] Scharcanski, J. and Celebi, M. E. (2013). *Computer vision techniques for the diagnosis of skin cancer*. Springer.

- [Silveira and Marques, 2008] Silveira, M. and Marques, J. S. (2008). Level set segmentation of dermoscopy images. In *2008 5th IEEE International Symposium on Biomedical Imaging: From Nano to Macro*, pages 173–176. IEEE.
- [Sookpotharom, 2009] Sookpotharom, S. (2009). Border detection of skin lesion images based on fuzzy c-means thresholding. In *Genetic and Evolutionary Computing, 2009. WGEN'09. 3rd International Conference on*, pages 777–780. IEEE.
- [Stolz, 1994] Stolz, W. (1994). Abcd rule of dermatoscopy: a new practical method for early recognition of malignant melanoma. *Eur. J. Dermatol.*, 4:521–527.
- [Szegedy et al., 2017] Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A. A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. In *Thirty-first AAAI conference on artificial intelligence*.
- [Vargas et al., 2016] Vargas, A. C. G., Paes, A., and Vasconcelos, C. N. (2016). Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In *Proceedings of the XXIX Conference on Graphics, Patterns and Images*, pages 1–4.
- [Villegas and Jaramillo, 1999] Villegas, M. and Jaramillo, F. (1999). Comportamiento clínico, epidemiológico e histológico del melanoma maligno en el departamento de caldas (colombia). *Rev Soc Col Dermatol*, 7:192–196.
- [Zaballos et al., 2004] Zaballos, P., Carrera, C., Puig, S., and Malvehy, J. (2004). Criterios dermatoscópicos para el diagnóstico del melanoma. *Med Cutan Iber Lat Am*, 32(1):3–17.
- [Zalaudek et al., 2006] Zalaudek, I., Argenziano, G., Soyer, H., Corona, R., Sera, F., Blum, A., Braun, R., Cabo, H., Ferrara, G., Kopf, A., et al. (2006). Three-point checklist of dermoscopy: an open internet study. *British Journal of Dermatology*, 154(3):431–437.
- [Zambrano et al., 2018] Zambrano, J. E. C., Alcivar, J. A. C., Vinces, R. Y. M., and Parrales, E. N. L. (2018). *Factores de riesgo asociados a enfermedades alérgicas en la población infantil de Manta*, volume 1. Casa Editora del Polo (CASEDELPO).