



INSTITUTO TECNOLÓGICO SUPERIOR DE MISANTLA

MODELO PARA LA CLASIFICACIÓN DE CÁNCER DE PIEL UTILIZANDO REDES NEURONALES PROFUNDAS

TESIS

PARA OBTENER EL GRADO DE:
MAESTRO EN SISTEMAS COMPUTACIONALES

P R E S E N T A

DUANNY HERNÁNDEZ BARBADILLO

DIRECTOR:

MSC. GALDINO MARTINEZ FLORES

CO-DIRECTOR:

DR. RAJESH ROSHAN BISWAL

MISANTLA, VERACRUZ

JUNIO 2020



INSTITUTO TECNOLÓGICO SUPERIOR DE MISANTLA
DIVISIÓN DE ESTUDIOS PROFESIONALES
AUTORIZACIÓN DE IMPRESIÓN DE TRABAJO DE TITULACIÓN MAESTRÍA

FECHA: 03 de Julio de 2020.

ASUNTO: **AUTORIZACIÓN DE IMPRESIÓN**
DE TESIS.

A QUIEN CORRESPONDA:

Por medio de la presente se hace constar que el (la) C:

DUANNY HERNÁNDEZ BARBADILLO

estudiante de la maestría en SISTEMAS COMPUTACIONALES con No. de Control 172T0798 ha cumplido satisfactoriamente con lo estipulado por el **Lineamiento de Posgrado para la obtención del grado de Maestría** mediante **Tesis.**

Por tal motivo se **Autoriza** la impresión del **Tema** titulado:

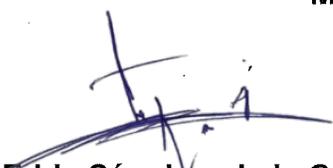
MODELO PARA LA CLASIFICACIÓN DE CÁNCER DE PIEL UTILIZANDO
REDES NEURONALES PROFUNDAS

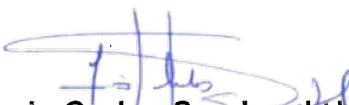
Dándose un plazo no mayor de un mes de la expedición de la presente a la solicitud del examen para la obtención del grado de maestría.

ATENTAMENTE


MSC. Galdino Martínez Flores
Presidente




Dr. Eddy Sánchez de la Cruz
Secretario


Dr. Luis Carlos Sandoval Herazo
Vocal

Archivo.

Dedicatoria

El presente trabajo está dedicado:

A mi madre

Por haberme apoyado en todo momento, gracias por su amor, consejos, apoyo por alentarme cuando las cosas no es tan bien. Siempre has sido la persona más importante en mi vida, es por ello que el culminar esta etapa es gracias a ti, te amo.

A mi esposo

Por su motivación, comprensión y ser mi apoyo incondicional en los momentos más difíciles.

A mí tía

Quien han velado por mí durante este arduo camino para convertirme en una profesional.

A mí familia

Porque me han brindado su apoyo incondicional y por compartir conmigo buenos y malos momentos.

Agradecimientos

Quiero agradecer en primer lugar a Dios, por guiarme en el camino y fortalecerme para empezar un camino lleno de éxito.

A mi familia el que me haya apoyado en todo momento en este difícil recorrido. En especial a mi madre, que ha hecho posible el que yo tuviera la oportunidad de formarme dónde, cuándo y según yo he decidido, aconsejándome y apoyándome en mis decisiones, a mi esposo a quien amo tanto y agradezco por tenerme tanta confianza, estar a mi lado en todo momento y darme su amor, a mi hermano por apoyarme en todo.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por la beca otorgada durante los dos años de estudios.

También dar las gracias a mis profesores, director de tesis y co-director por ayudarme a aprender y darme los medios para ello.

No olvido, por supuesto, a mis compañeros de estudio mis amigos Marcela, Caroline, Ivan, Alexis con los que tantas horas he pasado, y que han estado ahí en los suspensos y en los aprobados, por escucharme y por ayudarme a seguir, siempre.

Por último, quiero mostrar mi gratitud a todas aquellas personas que estuvieron presentes en la realización de esta meta que es tan importante para mí, agradecer todas sus ayudas, sus palabras motivadoras, sus conocimientos, sus consejos y su dedicación.

Resumen

Los sistemas de diagnóstico asistido por computadora basados en imágenes dermatoscópicas tienen un potencial significativo para la detección temprana del cáncer de piel. Las redes neuronales convolucionales profundas son una tecnología que está evolucionando muy rápidamente, se utilizan en el reconocimiento de imágenes para mejorar los sistemas de visión por computadora en tareas de clasificación de imágenes, detección de objetos y de segmentación. El desarrollo de tecnologías en las áreas de procesamiento de imágenes nos ha permitido el desarrollo de sistemas de diagnóstico que pueden ayudar al médico experto a tomar mejores decisiones sobre la salud de los pacientes y diferenciar el melanoma maligno de los benignos. Estas tecnologías permiten no solo la detección temprana del melanoma, si no también la reducción de la gran cantidad de procedimientos de biopsia innecesarios y costosas. El objetivo de este trabajo es clasificar imágenes de diferentes lesiones cutáneas, particularmente en la detección temprana de cáncer de piel (melanoma) y se presenta un enfoque basado en el aprendizaje profundo para resolver el problema de la clasificación de problemas de la piel que contiene una lesión cutánea como benigna y maligna a través de redes neuronales convolucionales profundas.

Abstract

Dermoscopic image-based computer-assisted diagnostic systems have significant potential for early detection of skin cancer. Deep convolutional neural networks are a technology that is evolving very rapidly, they are used in image recognition to improve computer vision systems in image classification, object detection and segmentation tasks.

The development of technologies in the areas of image processing has allowed us to develop diagnostic systems that can help the expert doctor make better decisions about the health of patients and differentiate malignant melanoma from benign melanoma that does not require biopsy. These technologies allow not only the early detection of melanoma, but also the reduction of the large number of unnecessary and expensive biopsy procedures.

The objective of this work is to classify images of different skin lesions, particularly in the early detection of skin cancer (melanoma) and an approach based on deep learning is presented to solve the problem of classifying skin problems that contains a as benign and malignant skin lesion through deep convolutional neural networks.

Índice general

Dedicatoria	III
Agradecimientos	IV
Resumen	VI
Abstract	VII
1. Generalidades	3
1.1. Introducción	4
1.2. Motivación	5
1.3. Planteamiento del problema	5
1.4. Propuesta de solución	5
1.5. Justificación	6
1.6. Hipótesis	6
1.7. Objetivos	7
1.7.1. Objetivo General	7
1.7.2. Objetivos Específicos	7
1.8. Alcances y limitaciones	8
1.8.1. Alcances	8
1.8.2. Limitaciones	8

1.9. Estructura de la tesis	9
2. Marco teórico	10
2.1. Definiciones y Conceptos	11
2.1.1. Qué es un dataset	11
2.1.2. Qué es una imagen digital	12
2.1.3. Tipos de imágenes	12
2.2. Pre-procesamiento	13
2.2.1. Espectro electromagnético	13
2.2.2. Conformación del color	13
2.2.3. Constancia del color	14
2.3. Segmentación de imágenes	14
2.3.1. Métodos de segmentación	15
2.4. Extracción de características	16
2.5. Técnicas de extracción de características	16
2.6. Marco contextual dermatológico	19
2.6.1. La piel	19
2.6.2. Cáncer de piel	20
2.6.3. Dermatoscopía	21
2.7. Machine Learning	22
2.8. Aprendizaje profundo	23
2.9. Redes neuronales biológicas	24
2.10. Redes Neuronales Artificiales	25
2.11. Redes Neuronales convolucionales	26
2.12. MobileNet	28
2.13. Métricas de evaluación	28
2.13.1. Matriz de confusión	28

2.13.2. Funcionamiento	29
3. Estado del arte	31
4. Metodología	37
5. Resultados y Análisis	43
5.1. Experimento I	44
5.1.1. Modelo de red	44
5.2. Experimento II	46
5.2.1. Características de las imágenes	47
5.2.2. Modelo de red	50
6. Conclusiones y trabajo a futuro	52
6.1. Conclusiones	53
6.2. Trabajo a futuro	53

Índice de figuras

2.1. Espectro electromagnético visible e invisible por el ojo humano [10]	13
2.2. Estructura de la piel [12]	20
2.3. Tipos de melanoma [48].	21
2.4. Dermatoscopio [15]	22
2.5. Técnicas de aprendizaje automático [21].	23
2.6. Neurona biológica [20].	25
2.7. Estructura de la Red neuronal Convolutiva [24]	27
4.1. Diagrama de la metodología	38
5.1. Curvas de entrenamiento	45
5.2. Matriz de confusión	46
5.3. Estructura de la red	47
5.4. Representación de las clases	47
5.5. Tipo de categoría	48
5.6. Localización de las lesiones cutáneas	49
5.7. Distribución de mujeres y hombres	49
5.8. Análisis de canal de color	50
5.9. Curvas de entrenamiento	51
5.10. Matriz de confusión	51

Índice de tablas

2.1. Matriz de confusión [32]	29
4.1. Distribución de las imágenes de la base de datos para cada clase [48].	41
5.1. Resumen de la ejecución de los datos de entrenamiento	45

Capítulo 1

Generalidades

1.1. Introducción

El cáncer es una de las enfermedades que afecta a la población de todo el mundo. Este padecimiento se da a raíz del crecimiento descontrolado de las células al alterarse los mecanismos de división y muerte celular, lo que genera el desarrollo de tumores o masas anormales, las cuales se pueden presentar en cualquier parte del organismo [1].

El cáncer de piel es la neoplasia maligna más común a nivel mundial, es una enfermedad producida por el desarrollo de células cancerosas en las capas de la piel, se divide en dos grupos principales, el melanoma maligno y el cáncer de piel no melanoma que a su vez se divide en tres tipos de cáncer que son: basalioma, queratosis actínica y carcinoma espinocelular [2].

El diagnóstico temprano del melanoma es crucial y podría conducir a un tratamiento exitoso, en la vida real ir a consulta con un dermatólogo implica un coste elevado en la mayoría de los casos por ello se han creado diferentes desarrollos para que la detección del melanoma sea una posibilidad real. La llegada de la dermatoscopia ha permitido un aumento en la capacidad de diagnóstico clínico hasta el punto de que el melanoma puede detectarse en las etapas más tempranas. Esta tecnología ha permitido grandes colecciones de imágenes de melanomas y lesiones benignas. El desarrollo de tecnologías en las áreas de procesamiento de imágenes y aprendizaje automático permiten no solo la detección temprana del melanoma, sino también la reducción de la gran cantidad de procedimientos de biopsia innecesarias y costosas.

1.2. Motivación

El cáncer de piel es una enfermedad dermatológica muy peligrosa y por desgracia más y más gente sufre de esto. Esta enfermedad puede atacar a cualquier edad, no solo afecta la piel, sino que puede tener un gran impacto en la vida de una persona, ya que puede aplastar la confianza en sí mismo, restringir su movimiento, y llevan incluso a la depresión, como en todas las enfermedades, el diagnóstico anticipado podría salvar vidas y conducir a un tratamiento exitoso.

1.3. Planteamiento del problema

La piel es el órgano más grande presente en el cuerpo humano [11]. El cáncer de piel es una enfermedad que no solo afecta la piel, sino que puede tener un gran impacto en la vida cotidiana de una persona, aplastar la confianza en sí mismo, restringir su movimiento, y llevan incluso a la depresión. En México, el Registro Histopatológico de Neoplasias Malignas reportó que el 14.6 % de las neoplasias malignas a nivel nacional corresponden a cáncer de piel [3]. El diagnóstico temprano del melanoma es crucial y podría conducir a un tratamiento exitoso.

1.4. Propuesta de solución

Para solucionar esta problemática, se propone clasificar imágenes dermatoscópicas relacionadas con el cáncer de piel a través de redes neuronales profundas para poder clasificar si la lesión en la piel es benigna o maligna. El procesamiento de las imágenes será llevado a cabo en los diferentes patrones de la piel y será analizado para obtener los resultados y luego clasificarlos mediante aprendizaje profundo.

1.5. Justificación

El cáncer de piel es la neoplasia maligna más común a nivel mundial, es una enfermedad producida por el desarrollo de células cancerosas en las capas de la piel. Se divide en dos grupos principales, el melanoma maligno y el cáncer de piel no melanoma que a su vez se divide en tres tipos de cáncer que son: basalioma, queratosis actínica y carcinoma espinocelular [2].

Las redes neuronales profundas muestran un gran potencial para realizar tareas altamente variables. Estudios como el de Lau y Al-Jumaily. que proponen un sistema de clasificación automático de cáncer de piel y se estudia la relación de la imagen de cáncer de piel en diferentes tipos de red neuronal con diferentes tipos de pre-procesamiento [44], demuestran que el reconocimiento de exactitud de las capas de la retro propagación es 89,9% y la red neural auto-asociativa es 80,8%. Lo que nos demuestra que una inteligencia artificial es capaz de clasificar el cáncer de piel con un nivel de competencia.

Esta tesis tiene como objetivo la clasificación de imágenes dermatoscópicas para poder reconocer si la lesión en la piel es melanoma maligno o benigno, con la ayuda de técnicas de procesamiento y redes neuronales profundas.

1.6. Hipótesis

A través del entrenamiento de una red neuronal profunda y el pre-procesamiento, con una base de datos de imágenes dermatoscópicas de cáncer de piel es posible clasificar si la lesión en la piel es benigno o melanoma maligno.

1.7. Objetivos

1.7.1. Objetivo General

El objetivo de este trabajo de tesis es crear un modelo que apoye al proceso de identificar y clasificar imágenes dermatoscópicas relacionadas con el cáncer de piel a través de redes neuronales profundas.

1.7.2. Objetivos Específicos

- Realizar el pre-procesamiento a las imágenes del dataset para una mejor tratamiento.
- Obtener las características más importantes de las imágenes para su mejor clasificación.
- Aplicar las técnicas de aprendizaje automático (redes neuronales profundas) sobre el dataset obtenido para conocer su precisión.
- Analizar y desarrollar las pruebas suficientes para obtener los valores necesarios para la evaluación de la red Neuronal.
- Evaluar los resultados de la red Neuronal profunda.

1.8. Alcances y limitaciones

1.8.1. Alcances

- Detectar correctamente el área con la lesión.
- Extraer características de la lesión.
- Clasificar las imágenes en función de las características extraídas.
- Clasificar correctamente el tipo de melanoma ya sea maligno o benigno dependiendo de las muestras del dataset.

1.8.2. Limitaciones

- El acceso a imágenes de cáncer de piel es difícil por lo delicado y confidencialidad de los datos es por ello que en esta investigación no se tubo acceso a un dataset de imágenes dermatoscópicas de México pero se utilizo un dataset llamado "Human Against Machine con 10000 imágenes de entrenamiento", es una gran colección de imágenes dermatoscópicas de múltiples fuentes de lesiones cutáneas pigmentadas comunes.
- El objetivo de este estudio no es remplazar al especialista si no ser un paliativo en la identificación de esta enfermedad como medida de precaución.

1.9. Estructura de la tesis

Este documento se encuentra organizado en capítulos, mismos que a continuación se describen: En el primer capítulo contiene el planteamiento general de la tesis donde se explican las generalidades, hacia donde se dirige el presente trabajo, en ella se detallan lo que se pretende resolver y la forma de solucionarlo; la introducción explica sobre el tema a tratar, se establece el planteamiento del problema, objetivo general y objetivos específicos, hipótesis, propuesta de solución, alcances y limitaciones de la investigación. En el segundo capítulo contiene el marco teórico donde se encuentra la nomenclatura utilizada para la comprensión del lector; hay dos secciones importantes en ella que son los conceptos y el estado del arte, primero se definen conceptos de la investigación y en estado del arte se encuentran los trabajos previos a este tema, que sirven como sustento para la realización del presente trabajo. En el tercer capítulo muestra las etapas de la metodología de solución donde explica el proceso que se hace para realizar la clasificación. El cuarto capítulo contiene experimentos y resultados, es el cuarto capítulo, donde se describen los experimentos y la clasificación de los datos, de acuerdo a la metodología definida anteriormente. El capítulo cinco contiene el análisis de resultados donde se muestran las matrices de confusión. Conclusiones y trabajo a futuro es el capítulo seis, donde se plantean comentarios de la culminación de esta investigación y se establece lo que se puede realizar más adelante.

Capítulo 2

Marco teórico

En este capítulo se presentan conceptos teóricos sobre el proceso de descubrimiento de conocimiento en datos y la explicación de lo que es el cáncer de piel.

2.1. Definiciones y Conceptos

2.1.1. Qué es un dataset

Un conjunto de datos o dataset corresponde a los contenidos de una única tabla de base de datos o una única matriz de datos de estadística, donde cada columna de la tabla representa una variable en particular, y cada fila representa a un miembro determinado del conjunto de datos que estamos tratando. En un conjunto de datos o dataset tenemos todos los valores que puede tener cada una de las variables, como por ejemplo la altura y el peso de un objeto, que corresponden a cada miembro del conjunto de datos, cada uno de estos valores se conoce con el nombre de dato. El conjunto de datos puede incluir datos para uno o más miembros en función de su número de filas.

El dataset incluye también las relaciones entre las tablas que contienen los datos.

Si nos movemos en el contexto de Big Data, entendemos por dataset aquellos conjuntos de datos tan grandes que las aplicaciones de procesamiento de datos tradicionales no los pueden procesar debido a la gran cantidad de datos contenidos en la tabla o matriz.

Podríamos definir un dataset como una colección o representación de datos residentes en memoria con un modelo de programación relacional coherente e independientemente sea cual sea el origen de los datos que contiene.

Una de las principales características de los datasets es que ya tienen una estructura, a diferencia de los RDD, conocidos como conjuntos de datos des-estructurados y definidos como una colección de elementos tolerante a fallos y son capaces de operar en paralelo [4].

2.1.2. Qué es una imagen digital

Podemos definir una imagen como una función bidimensional $f(x_1, x_2)$ donde $x = (x_1, x_2)$ son las coordenadas espaciales, y el valor de f en cualquier x es la intensidad de la imagen en dicho punto. Desde este punto de vista, una imagen puede considerarse como una función continua definida sobre un conjunto continuo (imagen analógica) o como una función discreta definida sobre un dominio discreto (imagen digital). Ambos puntos de vista resultan útiles en el procesamiento de imágenes. Convertir una imagen analógica a digital requiere que tanto las coordenadas como la intensidad sean digitalizadas. Digitalizar las coordenadas se llama muestrear, mientras que digitalizar la intensidad se denomina cuantizar. Entonces, cuando todas las cantidades son discretas, llamamos a la imagen una imagen digital [5].

2.1.3. Tipos de imágenes

- La imagen de intensidad es una matriz de datos cuyos valores han sido escalados para que representen intensidades de una escala de grises. Los elementos de una imagen de intensidad son de clase uint8 (enteros almacenados en 8 bits) o de clase uint16 (enteros almacenados en 16 bits) y pueden almacenar, respectivamente, $2^8=256$ valores en el rango $[0,255]$, o $2^{16}=65536$ valores en el rango $[0,65535]$. Cuando la imagen es de clase float32, los valores son números en punto flotante (que se almacenan en 32 bits). En este último caso, los valores suelen tomarse en el rango $[0,1]$ o en el rango $[0,255]$, indistintamente.
- La imagen binaria es una imagen en blanco y negro. Cada píxel tiene asignado un valor lógico de 0 ó 1.
- La imagen en color es como la imagen de intensidad pero tiene tres canales, es decir, a cada píxel le corresponden tres valores de intensidad (RGB) en lugar de uno [6].

2.2. Pre-procesamiento

2.2.1. Espectro electromagnético

Las fuentes luminosas emiten diferentes longitudes de onda, en donde cada longitud de onda visible define un color. De todas las longitudes de onda existentes, el ser humano es capaz de visualizar sólo un subconjunto. Este se encuentra conformado por longitudes de ondas que van desde los 380 nanómetros que corresponde al violeta, hasta los 730 nanómetros que corresponde al rojo [8]. Esto se puede visualizar en la figura 2.1.

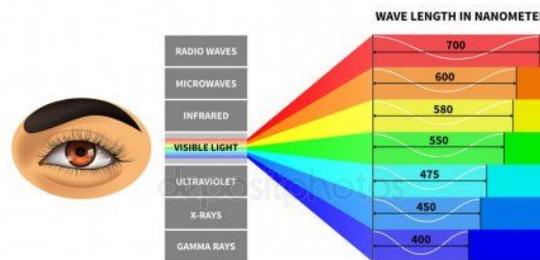


Figura 2.1: Espectro electromagnético visible e invisible por el ojo humano [10]

2.2.2. Conformación del color

La respuesta de una cámara o del sistema de visión humano a una escena está determinado por 3 factores: la iluminación del ambiente, la propiedad de reflectancia del objeto y la sensibilidad del sensor del sistema de visión. Considerando que la luz es uniforme en la escena, la formación del color en una imagen esta dado por el modelo simplificado [9]

2.2.3. Constancia del color

La constancia del color radica en un proceso inherente al ser humano en el cual consiste que la mayoría de las superficies mantienen la composición cromática ante cambios en la iluminación [9]. Es decir, los colores se siguen percibiendo de la misma manera como si estos son un atributo constante del objeto. Lo que sucede es que el ser humano realiza una corrección, cuando llega la luz refractada por un objeto, para visualizar siempre el mismo color. Por otro lado, en lo que respecta a la visión por computadora, las imágenes capturadas por una cámara no realizan este proceso de constancia del color. Con lo cual, la fuente de luz tiene influencia en la conformación del color de la imagen capturada y por ende se trata de emular la corrección realizada por el sistema de visión humano mediante la aplicación de algoritmos.

2.3. Segmentación de imágenes

En el campo del procesado de la imagen y la visión artificial, el concepto de segmentación [50] engloba el conjunto de técnicas y procesos que hacen posible localizar y separar determinados objetos de interés en la imagen, con el fin de facilitar su posterior procesado o extraer únicamente la información de interés. En la práctica el resultado de la segmentación es la asignación de etiquetas a los píxeles que, por sus características, se consideran parte de un objeto determinado. Los algoritmos de segmentación típicos se basan o bien en la detección de discontinuidades en el nivel de gris de la imagen, o agrupando zonas con características similares.

2.3.1. Métodos de segmentación

- **Método de umbralización (thresholding):** Es un método que busca segmentar imágenes escalares creando una partición binaria de las intensidades de las imágenes.

Una umbralización trata de determinar un valor de intensidad, llamado umbral (threshold), que separa la clases deseadas. La segmentación se logra agrupando todos los píxeles con mayor intensidad al umbral en una clase, y todos los otros píxeles en otra clase. Un método popular es umbralización método de Otsu que convierten una imagen de escala de grises en una imagen binaria. Los dos niveles de la imagen binaria son asignada a los píxeles aquellos están por encima o por debajo del valor umbral [26].

- **Método de segmentación basado en bordes:** Los métodos de segmentación basados en bordes se basan en el cambio rápido del valor de intensidad en una imagen porque un solo valor de intensidad no proporciona buena información sobre los bordes. Las técnicas de detección de bordes localizan los bordes y luego se conectan entre si para formar los limites del objeto. Para segmentar las regiones requeridas los métodos básicos de segmentación basados en bordes son dos: histograma en gris y métodos basados en gradientes. Para detectar los bordes se puede utilizar una de las técnicas básicas de detección de aristas como el operador Sobel, el operador Astuto y el operador de Robert, el resultado de estos métodos es básicamente una imagen binaria. Estas son las técnicas estructurales basadas en detección de discontinuidad.

2.4. Extracción de características

La extracción de características consiste básicamente en la tarea de localizar puntos de interés en una imagen dada, los cuales, contienen una alta cantidad de información relevante sobre su entorno y son invariables ante las perturbaciones que puede sufrir una imagen, es decir, son reproducibles.

Para lograr clasificar correctamente las imágenes dermatoscópicas se debe asegurar que la representación de las imágenes de una misma clase sea lo más similar posible. En otras palabras, en la representación por puntos de interés se debe lograr que en imágenes diferentes de la misma clase se detecten los mismos puntos de interés, en las mismas zonas y que estas zonas sean las más representativas de la imagen [28].

2.5. Técnicas de extracción de características

- Scale Invariant Feature Transform (SIFT): es un algoritmo de detección de puntos de interés que es invariante ante rotaciones y escalamientos. SIFT consiste en aplicar sobre la imagen una secuencia de diferencias gaussianas centradas en cada uno de los píxeles de la imagen en una escala σ determinada, esto produce un efecto de suavizado y pérdida del detalle de la imagen original a medida que los píxeles vecinos van perdiendo influencia una vez se van alejando del píxel principal. La diferencia de gaussianas actúa como detector de contornos o áreas con intensidad homogénea (BLOBS) rodeadas de zonas oscuras o claras [29].
- Speeded-Up Robust Features (SURF): este algoritmo aproxima el Laplaciano de Gaussianas (LoG) mediante filtros cuadrados, lo cual implica mayor rapidez debido a que su convolución puede ser calculada mediante el uso de imágenes integrales. SURF también usa el determinante de la matriz Hessiana para hallar

BLOBS en lugares donde este es máximo y seleccionar la escala [29].

- El Análisis Discriminante Lineal o Linear Discriminant Analysis (LDA) es un método de clasificación supervisado de variables cualitativas en el que dos o más grupos son conocidos a priori y nuevas observaciones se clasifican en uno de ellos en función de sus características. Haciendo uso del teorema de Bayes, LDA estima la probabilidad de que una observación, dado un determinado valor de los predictores, pertenezca a cada una de las clases de la variable cualitativa, $P(Y = k|X = x)$. Finalmente se asigna la observación a la clase k para la que la probabilidad predicha es mayor [30].

Es una alternativa a la regresión logística cuando la variable cualitativa tiene más de dos niveles. Si bien existen extensiones de la regresión logística para múltiples clases, el LDA presenta una serie de ventajas:

- Si las clases están bien separadas, los parámetros estimados en el modelo de regresión logística son inestables. El método de LDA no sufre este problema.
- Si el número de observaciones es bajo y la distribución de los predictores es aproximadamente normal en cada una de las clases, LDA es más estable que la regresión logística.

Cuando se trata de un problema de clasificación con solo dos niveles, ambos métodos suelen llegar a resultados similares

El proceso de un análisis discriminante puede resumirse en 6 pasos:

- Disponer de un conjunto de datos de entrenamiento (training data) en el que se conoce a que grupo pertenece cada observación.

- Calcular las probabilidades previas (prior probabilities): la proporción esperada de observaciones que pertenecen a cada grupo.
 - Determinar si la varianza o matriz de covarianzas es homogénea en todos los grupos. De esto dependerá que se emplee LDA o QDA.
 - Estimar los parámetros necesarios para las funciones de probabilidad condicional, verificando que se cumplen las condiciones para hacerlo.
 - Calcular el resultado de la función discriminante. El resultado de esta determina a qué grupo se asigna cada observación.
 - Utilizar validación cruzada (cross-validation) para estimar las probabilidades de clasificaciones erróneas.
- Principal Component Analysis (PCA): es un método estadístico que permite simplificar la complejidad de espacios muestrales con muchas dimensiones a la vez que conserva su información. Supóngase que existe una muestra con nn individuos cada uno con pp variables $(X_1X_1, X_2X_2, \dots, X_pX_p)$, es decir, el espacio muestral tiene pp dimensiones. PCA permite encontrar un número de factores subyacentes $(z < p)(z < p)$ que explican aproximadamente lo mismo que las pp variables originales. Donde antes se necesitaban pp valores para caracterizar a cada individuo, ahora bastan zz valores. Cada una de estas zz nuevas variables recibe el nombre de componente principal [31].

2.6. Marco contextual dermatológico

2.6.1. La piel

La piel humana es el órgano más grande del cuerpo humano está constituida por tres capas, la epidermis, la dermis y la hipodermis o tejido celular subcutáneo la estructura de la piel se muestra en la figura 2.2.

- La epidermis es la capa más externa de la piel. Está constituida fundamentalmente por dos tipos de células apiladas en capas: queratinocitos y melanocitos. Los queratinocitos se sitúan en la capa más externa y están compuestas fundamentalmente por queratina; son las células encargadas de la protección externa de la piel y se renuevan continuamente. Los melanocitos, por otra parte, se encargan de la protección contra la radiación ultravioleta y son los que confieren a la piel su pigmentación natural. Por último, en la capa más profunda de la epidermis se encuentran otro tipo de células, las de Langerhans, que forman parte del sistema inmunológico.
- La dermis se sitúa bajo la epidermis y es la capa de mayor espesor. Está compuesta principalmente por fibras de colágeno y elastina, que confieren a la piel su consistencia fuerte, flexible y elástica. Pero en esta capa también se encuentran distintos tipos de células inmunológicas, glándulas sudoríparas, vasos sanguíneos, folículos sebáceos, músculos piloerectores, y receptores sensoriales capaces de captar presión y temperatura, así como estímulos dolorosos. Un tipo de musculatura de tipo estriado se encarga de fijar la piel al músculo.
- Por último, el tejido subcutáneo o hipodermis, compuesto por tejidos adiposos y macrófagos. Se encarga de conservar la temperatura corporal, y proporciona mayor o menor flexibilidad de la piel en las distintas zonas del cuerpo. En esta capa también se encuentran vasos sanguíneos y linfáticos [11].

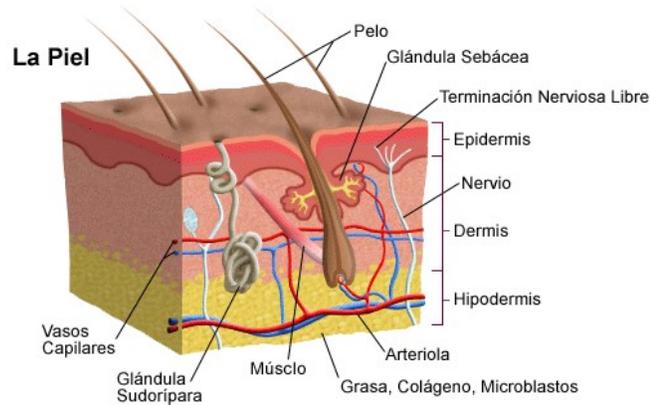


Figura 2.2: Estructura de la piel [12]

2.6.2. Cáncer de piel

El cáncer de piel es el tipo de cáncer cuya tasa de incidencia ha aumentado más en el mundo

Se divide en dos grupos principales:

- Melanoma maligno (MM)
- Cáncer de piel no melanoma (CPNM)

Dentro de los cánceres de piel no melanoma, el carcinoma basocelular (CBC) y el carcinoma espinocelular (CEC) son dos de los tipos más comunes, ambos altamente curables.

El melanoma maligno es sumamente mortal si no es diagnosticado en etapas tempranas, donde presenta una alta tasa de sobre vida. Además es uno de los cánceres más prevalentes entre los adultos jóvenes los tipos de enfermedad cutáneas de muestran el la siguiente figura 2.3 [13].

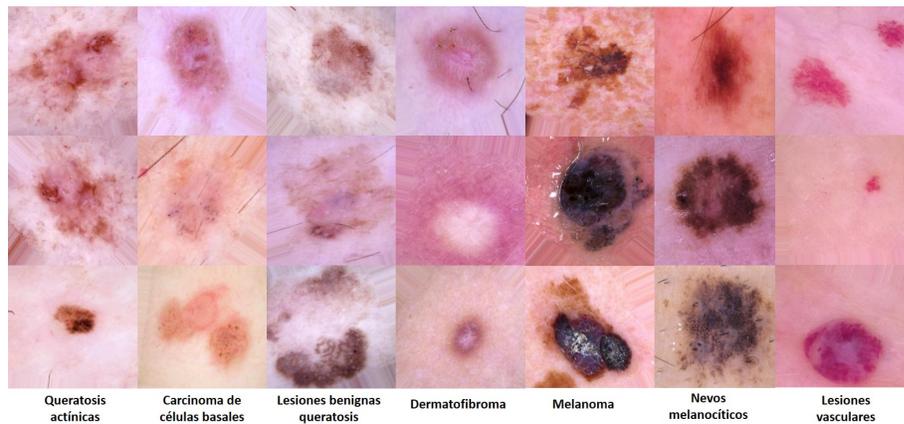


Figura 2.3: Tipos de melanoma [48].

2.6.3. Dermatoscopía

La dermatoscopia también llamada microscopía de epiluminiscencia, es una técnica no invasiva de diagnóstico que mediante un instrumento llamado dermatoscopio permite examinar las lesiones por debajo de la superficie cutánea amplificando la imagen y eliminando los fenómenos de refracción y reflexión de la luz [14].

El dermatoscopio 2.4 es un microscopio o estereomicroscopio ya que dispone de un lente óptico con una amplificación y un juego de leds que constituyen una fuente de luz de polarización cruzada y lineal. La polarización lineal ilumina la superficie de la lesión mientras que la cruzada disminuye el reflejo provocado por la epidermis pudiendo visualizar estructuras anatómicas de la epidermis que a simple vista no podrían ser observadas. Cuando se acopla el dermatoscopio a una cámara digital, se capturan las llamadas imágenes dermatoscópicas.



Figura 2.4: Dermatoscopio [15]

2.7. Machine Learning

El aprendizaje automático consiste en desarrollar procesos que permitan a las máquinas aprender por sí solas a partir de conjuntos de datos que un instructor va introduciendo.

El aprendizaje automático utiliza dos tipos de técnicas como se muestra en la figura 2.5:

- **Aprendizaje supervisado:** En el aprendizaje supervisado, los datos de entrenamiento que alimenta al algoritmo incluyen las soluciones deseadas, llamadas etiquetas. Una típica tarea de aprendizaje supervisado es la clasificación.
- **Aprendizaje no supervisado:** En el aprendizaje no supervisado, los datos de entrenamiento no están etiquetados (el sistema intenta aprender sin un maestro [16]).

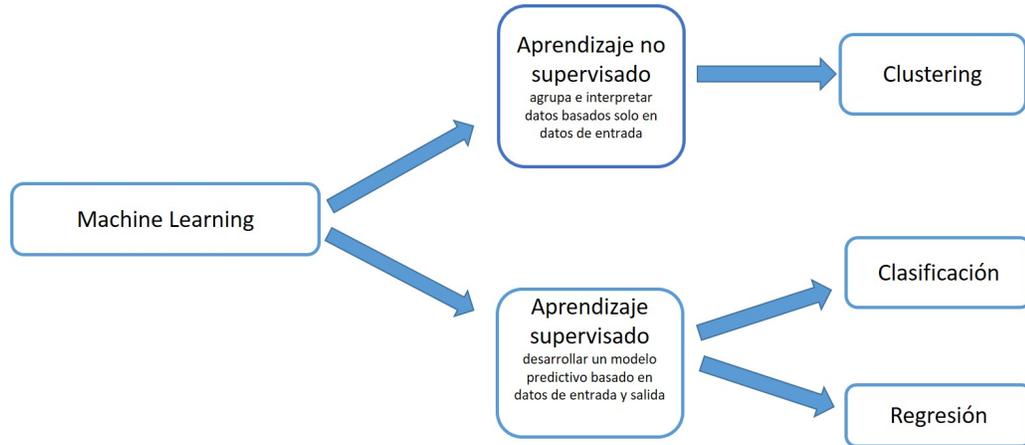


Figura 2.5: Técnicas de aprendizaje automático [21].

2.8. Aprendizaje profundo

El aprendizaje profundo, también conocido como redes neuronales profundas, es un aspecto de la inteligencia artificial (AI) que se ocupa de emular el enfoque de aprendizaje que los seres humanos utilizan para obtener ciertos tipos de conocimiento. En su forma más simple, el aprendizaje profundo puede considerarse como una forma de automatizar el análisis predictivo.

Se le llama aprendizaje profundo porque presenta una estructura jerárquica que profundiza hasta diferentes niveles de detalle. Cuantos más datos tenga un dispositivo, mejor será capaz de predecir qué cosas son. Es como llevar el aprendizaje automático al próximo nivel [17].

2.9. Redes neuronales biológicas

Para una computadora el reconocer imágenes es una tarea sumamente difícil, lo que en el caso de los humanos es algo relativamente sencillo. Esto se debe a que los sistemas biológicos poseen una arquitectura distinta a la de una computadora moderna. Por tal motivo, se trata de simular algunas características del cerebro humano para elaborar nuevos modelos de cómputo [18].

Las redes neuronales artificiales pertenecen a una rama de los algoritmos de aprendizaje automático y se basan en el funcionamiento del cerebro humano. Aunque se está lejos de comprender el funcionamiento y la estructura del sistema nervioso, se conoce con cierto detalle la estructura de la neurona como elemento básico del tejido nervioso y la forma de cómo se estructura la corteza cerebral.

La neurona, como toda célula, consta de una membrana exterior (M), que la limita y le sirve de órgano de intercambio con el medio exterior, de un citoplasma (C), que es el cuerpo principal de la célula donde radica el grueso de sus funciones y de un núcleo (N), que contiene el material genético de la célula. El citoplasma presenta unos alargamientos (D), llamados dendritas, que son órganos de recepción. En las dendritas terminan un gran número de fibras (F) que son conductores que llevan la señal o impulso nervioso de los receptores hacia la neurona. Estas fibras terminan en un pequeño corpúsculo llamado sinapsis, que constituye un relevador bioquímico y que sirve para transferir la respuesta de la neurona (señal de salida) hacia otra neurona. Esta señal de salida es conducida por una prolongación cilíndrica alargada de la neurona, que se llama cilindro-eje o axón (A), que en su extremo se divide en varias fibras para comunicarse con otras neuronas o con órganos efectores o motores como pueden ser glándulas o músculos. Lo anteriormente explicado puede visualizarse en la figura 2.6 [19].

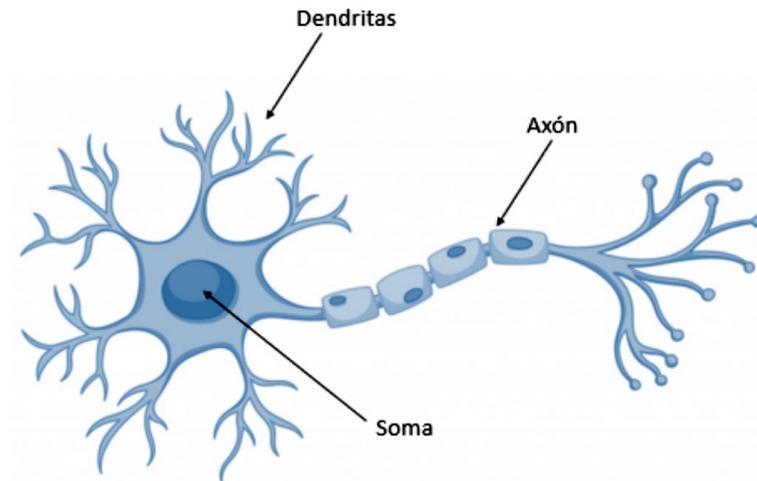


Figura 2.6: Neurona biológica [20].

2.10. Redes Neuronales Artificiales

Una red neuronal artificial (ANN) es un esquema de computación distribuida inspirada en la estructura del sistema nervioso de los seres humanos. La arquitectura de una red neuronal es formada conectando múltiples procesadores elementales, siendo éste un sistema adaptivo que posee un algoritmo para ajustar sus pesos (parámetros libres) para alcanzar los requerimientos de desempeño del problema basado en muestras representativas. Por lo tanto podemos señalar que una ANN es un sistema de computación distribuida caracterizada. Un conjunto de unidades elementales, cada una de las cuales posee bajas capacidades de procesamiento.

- Una densa estructura interconectada usando enlaces ponderados.
- Parámetros libres que deben ser ajustados para satisfacer los requerimientos de desempeño.

- Un alto grado de paralelismo.

Es importante señalar que la propiedad más importantes de las redes neuronales artificiales es su capacidad de aprender a partir de un conjunto de patrones de entrenamientos, es decir, es capaz de encontrar un modelo que ajuste los datos.

El proceso de aprendizaje también conocido como entrenamiento de la red puede ser supervisado o no supervisado.

El aprendizaje supervisado consiste en entrenar la red a partir de un conjunto de datos o patrones de entrenamiento compuesto por patrones de entrada y salida. El objetivo del algoritmo de aprendizaje es ajustar los pesos de la red de manera tal que la salida generada por la ANN sea lo más cercanamente posible a la verdadera salida dada una cierta entrada. Es decir, la red neuronal trata de encontrar un modelo al proceso desconocido que generó la salida.

Este aprendizaje se llama supervisado pues se conoce el patrón de salida el cual hace el papel de supervisor de la red. En cambio en el aprendizaje no supervisado se presenta sólo un conjunto de patrones a la ANN, y el objetivo del algoritmo de aprendizaje es ajustar los pesos de la red de manera tal que la red encuentre alguna estructura o configuración presente en los datos [22].

2.11. Redes Neuronales convolucionales

Redes Neuronales convolucionales (CNN) son las principales herramientas para el aprendizaje profundo y son ideales para el reconocimiento de imágenes, ya que pueden aprender directamente, cada neurona recibe una entrada y da una salida.

Las redes neuronales convolucionales son similares a las redes neuronales multicanal, su principal ventaja es que cada parte de la red se le entrena para realizar una tarea, esto reduce significativamente el número de capas ocultas, por lo que el entrena-

miento es más rápido. Además, presenta invarianza a la traslación de los patrones a identificar. Una red neuronal convolucional es una red multicapa que consta de capas convolucionales y de submuestreo alternadas, y al final tiene capas de conexión total como una red perceptrón multicapa su estructura se muestra en la figura 2.7 [23].

- **Convolución (convolution):** En la convolución se realizan operaciones de productos y sumas entre la capa de partida y los n filtros (o kernel) que genera un mapa de características. Las características extraídas corresponden a cada posible ubicación del filtro en la imagen original.
- **Reducción (pooling):** En la reducción se disminuye la cantidad de parámetros al quedarse con las características más comunes.
- **Clasificador (red perceptron multicapa):** El final de las capas convolucional y de reducción, se suele utilizar capas completamente conectadas en la que cada píxel se considera como una neurona separada al igual que en un perceptrón multicapa.

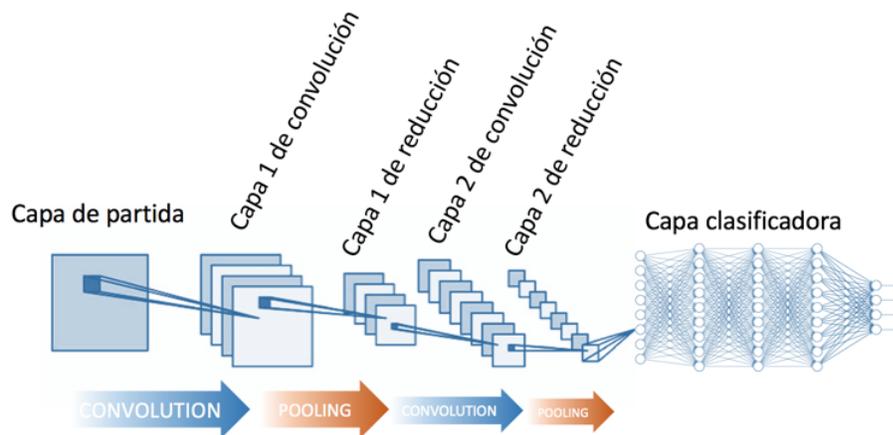


Figura 2.7: Estructura de la Red neuronal Convolucional [24]

2.12. MobileNet

Son modelos pequeños, de baja latencia y de baja potencia parametrizados para cumplir con las limitaciones de recursos de una variedad de casos de uso. Se pueden desarrollar para la clasificación, detección, incrustaciones y segmentación. La arquitectura mobileNet se basa en factorizar las convoluciones tradicionales en 2 tipos de capas, una primera capa convolucional “depthwise” y una capa convolucional “pointwise”. Esta división permite reducir el costo computacional y el tamaño del modelo. Se entreno el conjunto de datos ajustando todas las capas. El tamaño de las imágenes de entrada se redimensionó a (224, 224) para ser compatible con este modelo [49].

2.13. Métricas de evaluación

2.13.1. Matriz de confusión

Este apartado tiene como objetivo comprender la matriz de confusión de una manera muy simple, sabiendo que el campo del aprendizaje automático es muy vasto y tiene varios conceptos que comprender.

La matriz de confusión se utiliza para resumir, describir o evaluar el rendimiento de una tarea o modelo de clasificación binaria. El concepto clave de matriz de confusión es que calcula el no. de predicciones correctas e incorrectas que se resumen con el no. de valores de cuenta y desglose en cada clase. Eventualmente muestra la ruta en la que se confunde el modelo de clasificación cuando hace predicciones [32]

2.13.2. Funcionamiento

La matriz de confusión es una herramienta fundamental a la hora de evaluar el desempeño de un algoritmo de clasificación, ya que dará una mejor idea de cómo se está clasificando dicho algoritmo, a partir de un conteo de los aciertos y errores de cada una de las clases en la clasificación. Así se puede comprobar si el algoritmo está clasificando mal las clases y en que medida [32].

El desempeño de un sistema es usualmente evaluado usando los datos en dicha matriz. La siguiente tabla 2.1 muestra la matriz de confusión para un clasificador en dos clases:

		Predicción	
		Positivos	Negativos
Valores reales	Positivos	Verdaderos positivos (TP)	Falsos negativos (FN)
	Negativos	Falsos positivos (FP)	Verdaderos negativos (TN)

Tabla 2.1: Matriz de confusión [32]

Para poder evaluar el rendimiento de los clasificadores utilizados en el proceso de CNN, se usan métricas de evaluación generalmente utilizadas en recuperación de información, las cuales son adaptadas en función de los casos correctamente e incorrectamente clasificados.

Se definen de la siguiente manera:

- **Precisión:** También llamado valor de predicción positiva.

$$Precision = \frac{TP}{TP + FT} \quad (2.1)$$

- **Sensibilidad (“Recall”)**: También llamado como Tasa de Verdaderos Positivos (True Positive Rate) (TP).

$$\text{Sensibilidad} = \frac{TP}{TP + FN} \quad (2.2)$$

- **F1-score**: Es una medida general de la precisión de un modelo que combina precisión y recuperación.

$$F_1 = 2x \frac{\text{Precisi'on} * \text{Sensibilidad}}{\text{Precisi'on} + \text{Sensibilidad}} \quad (2.3)$$

Donde:

- **TP**: Es el número de casos positivos que están etiquetados correctamente en este caso sería aquellas lesiones pigmentadas clasificadas como melanomas y que efectivamente son melanomas.
- **TN**: Es el número de casos negativos que están etiquetados correctamente en este caso serian aquellas lesiones pigmentadas clasificadas como “no melanomas” y que efectivamente no son melanomas.
- **FP**: Es el número de casos positivos que están etiquetados falsamente en este caso serian aquellas lesiones pigmentadas clasificadas como melanomas pero que en realidad son “no melanomas”.
- **FN**: Es el número de casos negativos que están etiquetados falsamente en este caso sería aquellas lesiones pigmentadas clasificadas como “no melanomas” pero que en realidad son melanomas.

Capítulo 3

Estado del arte

Existen varios estudios en donde se aplica aprendizaje automático en la salud. Algunos de ellos tratan de problemas como la evaluación del riesgo de padecer alguna enfermedad, o para asistir en el tratamiento y pronóstico de otras enfermedades. En esta sección se presentan algunos trabajos encontrados en la literatura que tratan sobre este mismo tema.

Bajaj et. al; presentan el desarrollo de un sistema automático de diagnóstico de enfermedades de la piel y predice el tipo de enfermedad. El sistema utiliza un enfoque de dos etapas para el proceso de detección y predicción que amalgama eficazmente el procesamiento de imágenes y el aprendizaje automático. En la primera etapa, la imagen de la condición de la piel está sujeta a numerosos tipos de técnicas de pre-procesamiento, seguido de la extracción de características, las características extraídas para cada imagen se convierten después en un vector de características. En la segunda etapa, los vectores de características se alimentan a un algoritmo de aprendizaje automático (redes neuronales artificiales) para identificar la enfermedad y predecirla. La formación y las pruebas son para 5 enfermedades (eczema, psoriasis, impétigo, melanoma, y esclerodermia) el sistema produce una precisión global de predicción de 90% [33].

Ansari y Sarode; proponen un sistema de detección de cáncer de piel utilizando maquina de soporte vectorial para la clasificación y detección de la enfermedad. La metodología de diagnóstico utiliza métodos de procesamiento de imágenes y maquina de soporte vectorial (SVM). La imagen dermastocopicas de cáncer de piel se toma y se pasa por varias técnicas de preprocesamiento para la eliminación de ruido y mejora de la imagen, la imagen es sometida a la segmentación utilizando el método de umbrales. Algunas de las características de la imagen tienen que ser extraídas utilizando la metodología GLCM (matriz de coocurrencia de niveles de grises). La imagen dada se clasifica en no canceroso o canceroso [34].

Un grupo de estudiantes de la Universidad Banasthali, Rajasthan, India proponen un

sistema de diagnóstico de enfermedades de la piel que permite al usuario identificar las enfermedades de la piel para proporcionar tratamientos médicos en un periodo de tiempo muy corto, utilizan tecnologías tales como el procesamiento de imágenes y minería de datos para el diagnóstico de la enfermedad de la piel. Utilizan cinco diferentes algoritmos de clasificación de minería de datos (AdaBoost, BayesNet, J48, MLP y NaiveBayes) para predecir y diagnosticar la enfermedad de la piel, esto sólo funciona para tres enfermedades de la piel (eccema, impétigo y melanoma). Los investigadores presenta un clasificador basado en reglas difusas para discriminar un melanoma, un sistema adaptativo Neuro Fuzzy se aplica con el fin de descubrir las reglas difusas que conducen a la clasificación correcta. El método que utilizaron se llama ABCD y requiere el cálculo de 4 factores que son Asimetría (A), Frontera (B), Color (C) y diversidad (D). Este marco ha sido probado en una base de datos dermatoscópico de 320 imágenes. [35].

Gound et. al; proponen un sistema de diagnóstico basado en las técnicas de procesamiento de imágenes y la minería de datos. El sistema captura la imagen a través de la cámara de los teléfonos inteligentes y a cada imagen se le realiza el pre-procesamiento y la segmentación, luego la extracción de características, las características primitivas de la imagen pueden ser características generales, como la extracción de color, textura y forma o las características específicas del dominio. Después de la extracción de características, se puede hacer una clasificación de estas. El sistema comparará la imagen capturada con el conjunto de datos de entrenamiento utilizando técnicas de procesamiento de imágenes y decidirá si una piel, sufre enfermedades o si no utiliza el árbol de decisiones. Si hay una enfermedad, el sistema dará un consejo médico a través de la aplicación de Android [36].

Li y Shen; proponen dos métodos de aprendizaje profundo para abordar tres tareas principales que surgen en el área del procesamiento de imágenes de lesiones cutáneas, es decir, segmentación de lesiones (tarea 1), extracción de características

dermoscópicas de las lesiones (tarea 2) y clasificación de lesiones (tarea 3). Proponen un marco de aprendizaje profundo que consiste en dos redes convolucionales para producir simultáneamente el resultado de la segmentación y el resultado de la clasificación aproximada. Se desarrolla una unidad de cálculo del índice de lesiones (LICU) para refinar los resultados de clasificación calculando el mapa de calor de distancia, y una red neuronal convolucional (CNN) directa para la tarea de extracción de características dermatoscópicas. Los marcos de aprendizaje profundo propuestos se evaluaron en el conjunto de datos ISIC 2017 [37].

Lau y Al-Jumaily; proponen un sistema de clasificación automático de cáncer de piel y se estudia la relación de la imagen de cáncer de piel en diferentes tipos de red neuronal con diferentes tipos de pre-procesamiento. Las imágenes recopiladas se introducen en el sistema y en diferentes procedimientos de procesamiento de imágenes para mejorar las propiedades de la imagen, luego se elimina la piel normal del área afectada y se deja la célula cancerosa en la imagen. Se puede extraer información útil de estas imágenes y pasarla al sistema de clasificación para entrenamiento y pruebas [44].

GoDorj et al; proponen un sistema de clasificación inteligente y rápido de cáncer de piel utilizando una red neuronal convolucional profunda de alta eficiencia. En este documento, se centran principalmente en la tarea de clasificar el cáncer de piel utilizando ECOC SVM y una red neuronal convolucional profunda. Las imágenes RGB de los cánceres de piel se obtienen de internet. Algunas imágenes recopiladas tienen ruidos como otros órganos, Estas imágenes se recortan para reducir el ruido y obtener mejores resultados. En este artículo, se usa un modelo de red neuronal convolucional existente y preentrenado de AlexNet para extraer características. Un clasificador ECOC SVM se utiliza en la clasificación del cáncer de piel [39].

Singhal y Tiwari; proponen un sistema de clasificación de cáncer de piel y se estudia la relación de la imagen de cáncer de piel a través de la red neuronal con diferentes

tipos de pre-procesamiento. La imagen recopilada se introduce en el sistema y el pre-procesamiento de imágenes se utiliza para eliminar el ruido, las imágenes son segmentadas. Hay ciertas características únicas en la región del cáncer de piel que se extraen mediante la técnica multilevel 2-D. Estas características se dan a los nodos de entrada de la red neuronal. La red neuronal de propagación hacia atrás y la red neuronal básica radial se utilizan para fines de clasificación, que clasifica las imágenes dadas en cancerosas o no cancerosas [40].

Mhaske y Phalke; proponen un sistema para la detección y clasificación de cáncer de piel basada en aprendizaje supervisado y no supervisado, se realiza utilizando clasificadores basados en el aprendizaje supervisado como redes neuronales, maquina de soporte vectorial y la clasificación basada en el aprendizaje no supervisado como los algoritmos K-medias y agrupación. La precisión resultante se compara con estos diferentes clasificadores. La mayor precisión la obtuvieron con maquina de soporte vectorial. La precisión recibida por el algoritmo de agrupamiento K-medias es menor que la de red neuronal y maquina de soporte vectorial(SVM) [41].

Romero et. al; proponen una solución para ayudar a los dermatólogos en el diagnóstico de lesiones de la piel. Diseñaron, implementaron y compararon con éxito un método novedoso para la clasificación de las lesiones de la piel mediante aprendizaje profundo en comparación con un conjunto de datos de imágenes dermatoscópicas de lesiones de la piel (el conjunto de datos del Archivo ISIC). Los investigadores utilizan una arquitectura de red neuronal convolucional (CNN) existente VGGNet. El enfoque propuesto alcanza resultados prometedores en particular, un valor de sensibilidad de 78,66 % y una precisión de 79,74 % que son significativamente más altos que el estado actual de la técnica en este conjunto de datos (50,7 % y 63,7 %, respectivamente) [46].

Milton; propone una clasificación automatizada de las lesiones de la piel basado en aprendizaje profundo utilizando un conjunto de redes neuronales profundas como PNASNet-5-Large, InceptionResNetV2, SNet154, InceptionV4. Las imágenes dermatoscópicas se procesan y aumentan adecuadamente antes de introducirlas en la red. El autor probó los métodos en el conjunto de datos (ISIC) 2018. El enfoque propuesto tiene el mejor puntaje de validación para el modelo PNASNet-5-Large que es 0.76. Demostrando que un conjunto de métodos basados en redes neuronales profundas puede lograr una clasificación competitiva de la clasificación de imágenes dermatoscópicas para detectar lesiones en la piel [47].

Capítulo 4

Metodología

En este capítulo, se describe la metodología utilizada para la presente investigación como se muestra en el diagrama de la figura 4.1, la cual consta de 6 fases que son: análisis de la base de datos original, procesamiento de imágenes, segmentación de las imágenes, extracción de características de las imágenes, algoritmos de clasificación y el análisis de los resultados obtenidos.

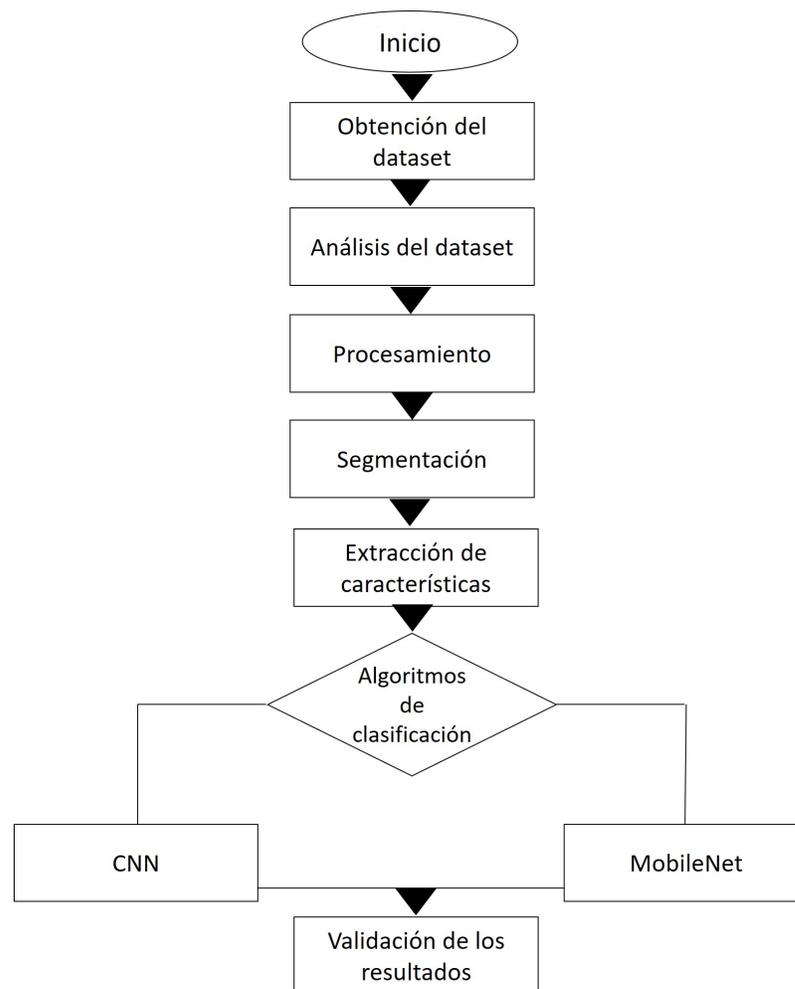


Figura 4.1: Diagrama de la metodología

Para lograr el objetivo del proyecto, se utilizara una red neuronal convolucional. El orden de ejecución será:

- **Fase 1 análisis de la base de datos original:** En esta fase se hace un análisis de el dataset. El conjunto de datos "Human Against Machine con 10000 imágenes de entrenamiento", es una gran colección de imágenes dermatoscópicas de múltiples fuentes de lesiones cutáneas pigmentadas comunes. El conjunto de datos final consta de 10015 imágenes dermatoscópicas con un tamaño de 450 600 e incluye 7 categorías diagnósticas de la siguiente manera: melanoma (Mel), nevus melanocíticos (NV), carcinoma de células basales (BCC), queratosis actínica y carcinoma intraepitelial (AKIEC), queratosis benigna (BKL), dermatofibroma (DF), lesiones vasculares (VASC) [48].

A continuación se encuentran las descripciones del tipo de lesiones de la piel:

- Nevos melanocíticos (nv): Los nevos melanocíticos son neoplasias benignas de melanocitos y aparecen en una miríada de variantes, todas ellas incluidas en nuestra serie. Las variantes pueden diferir significativamente desde un punto de vista dermatoscópico.
- Melanoma (mel): El melanoma es una neoplasia maligna derivada de los melanocitos que puede aparecer en diferentes variantes. Si se extirpa en una etapa temprana, se puede curar mediante escisión quirúrgica simple. Los melanomas pueden ser invasivos o no invasivos (in situ). Se incluyeron todas las variantes de melanoma, incluido el melanoma in situ, pero se excluyeron los melanomas no pigmentados, subungueales, oculares o de la mucosa.
- Queratosis benignas (bkl): La "queratosis benigna.^{es} una clase genérica que incluye queratosis seborreicas ("verruca senil"), lentigo solar, que puede considerarse una variante plana de la queratosis seborreica, y liquen plano como las queratosis (LPLK), que corresponde a un seborreico.

queratosis o un lentigo solar con inflamación y regresión. Los tres subgrupos pueden verse diferentes dermatoscópicamente, pero los agrupamos porque son similares biológicamente y con frecuencia se informan bajo el mismo término genérico histopatológicamente. Desde un punto de vista dermatoscópico, las queratosis similares a liquen plano son especialmente difíciles porque pueden mostrar características morfológicas que imitan el melanoma y a menudo se biopsian o extirpan por razones de diagnóstico.

- Carcinoma de células basales (bcc): El carcinoma de células basales es una variante común del cáncer epitelial de piel que rara vez hace metástasis pero crece de forma destructiva si no se trata. Aparece en diferentes variantes morfológicas (planas, nodulares, pigmentadas, quísticas, etc.), que se incluyen en este conjunto.
- Queratosis actínicas (akiec): Las queratosis actínicas (queratosis solares) y el carcinoma intraepitelial (enfermedad de Bowen) son variantes comunes no invasivas de carcinoma de células escamosas que pueden tratarse localmente sin cirugía. Sin embargo, existe acuerdo en que estas lesiones pueden progresar a carcinoma invasivo de células escamosas, que generalmente no está pigmentado. Ambas neoplasias comúnmente muestran escamas en la superficie y comúnmente carecen de pigmento. Las queratosis actínicas son más comunes en la cara y la enfermedad de Bowen es más común en otros sitios del cuerpo. Debido a que ambos tipos son inducidos por la luz ultravioleta, la piel circundante generalmente se caracteriza por daños severos causados por el sol, excepto en los casos de la enfermedad de Bowen causada por la infección por el virus del papiloma humano y no por los rayos UV. Existen variantes pigmentadas para la enfermedad de Bowen y para las queratosis actínicas. Ambos están incluidos en este conjunto.

- Lesión vascular (vasc): Las lesiones cutáneas vasculares en el conjunto de datos varían desde angiomas cereza hasta angioqueratomas y granulomas piógenos. La hemorragia también se incluye en esta categoría.
- Dermatofibroma (df): El dermatofibroma es una lesión cutánea benigna considerada como una proliferación benigna o una reacción inflamatoria a un trauma mínimo. Es de color marrón que a menudo muestra una zona central de fibrosis dermatoscópicamente.

A continuación en la tabla 4.1 se muestra el número de imágenes por clase. Podemos ver como el número de imágenes por clase es muy desequilibrado.

Tipo	Numero de imágenes
Melanoma	1,113
Melanocytic Nevus	6,705
Basal Cell Carcinoma	514
Actinic Keratosis	327
Benign Keratosis	1,099
Dermatofibroma	115
Vascular Lesions	141

Tabla 4.1: Distribución de las imágenes de la base de datos para cada clase [48].

- **Fase 2 procesamiento:** En esta fase se mejora el aspecto de las imágenes y así hacer más evidentes ciertos detalles que tienen, varias técnicas de procesamiento son necesarias.

Aunque se realizan algunas formas básicas de pre-procesamiento:

- Resta media. Para centrar la nube de valores RGB a partir de datos de entrada alrededor cero a lo largo de cada dimensión de la imagen, se aplica una resta media a través de las características de la imagen.
- Normalización de la imagen. Al dividir cada dimensión RGB de imágenes de entrada por su estándar desviación, se obtiene una normalización de

sus valores originales de 0 y 255 píxeles a 1 y 0 Valores normalizados. Esta técnica de pre-procesamiento evitará más problemas causados por una mal contraste de la imagen.

- Recorte de imagen y cambio de tamaño. Las imágenes de entrada están pre-procesadas para ser aceptadas para realizar la clasificación.
- **Fase 3 segmentación:** En esta fase se identifican y aíslan las áreas de interés de las imágenes, para centrar el análisis en dichas áreas. Los datos de entrenamiento y validación del conjunto de datos de segmentación se procesan con un script de Python para cargar las imágenes y aplicarse el método por umbral otsu (Thresholding) ya que proporciona el umbral óptimo para la segmentación de la imagen, bajo el criterio de máxima varianza entre fondo y objeto.
- **Fase 4 extracción de características:** En esta fase se hace posible la reducción de la complejidad (dimensionalidad) de una imagen mediante la transformación de los datos de entrada en un conjunto de rasgos que representan las características esenciales de la imagen.
- **Fase 5 algoritmos de clasificación:** En esta fase se aplica una red neuronal convolucional para poder realizar la clasificación de las imágenes utilizando el modelo MobileNet, la arquitectura mobileNet se basa en factorizar las convoluciones tradicionales en 2 tipos de capas, una primera capa convolucional “depthwise” y una capa convolucional “pointwise”. Esta división permite reducir el costo computacional y el tamaño del modelo [49].
- **Fase 6 validación de los resultados:** En esta fase se hace un análisis de los resultados que se obtuvieron utilizando las medidas de precisión de los algoritmos, ofreciendo argumentos y valoraciones que demuestren la factibilidad y precisión de la clasificación.

Capítulo 5

Resultados y Análisis

Este capítulo muestra y analiza los resultados obtenidos, para llegar a ellos se implementaron los métodos previamente denidos y se realizaron los siguientes experimentos.

5.1. Experimento I

En esta primera fase se presenta el diseño de una red neuronal convolucional utilizando el modelo de red MobileNet, su arquitectura hace uso de convoluciones separables en profundidad que ayudan a reducir el número de parámetros de entrenamiento, haciendo que el modelo sea más liviano.

Para realizar la clasificación se utilizan un total de siete tipos diferentes de clases principales de cáncer de piel melanoma (Mel, 1113), nevus melanocíticos (NV, 6705), carcinoma de células basales (BCC, 514), queratosis actínica y carcinoma intraepitelial (AKIEC, 327), queratosis benigna (BKL, 1099), dermatofibroma (DF, 115), lesiones vasculares (VASC, 142).

El tamaño original de cada una de las imágenes era de 600x450 píxeles.

5.1.1. Modelo de red

Dado que el conjunto de datos estaba significativamente desequilibrado (como es el caso con la mayoría de los conjuntos de datos sobre el cáncer), se utilizó el generador de datos de imagen Keras para aumentar y equilibrar selectivamente los datos antes de entrenar el modelo.

Para obtener los resultados se dividieron los datos en 83% el conjunto de entrenamiento y el conjunto de datos de prueba contiene el 17%. Se Capacito el modelo en el conjunto de datos de entrenamiento para un total de 30 épocas los resultados

fueron los siguientes tabla 5.1.

Categorías	precisión	sensibilidad	f1-score	soporte
akiec	0.27	0.62	0.38	26
bcc	0.64	0.70	0.67	30
bkl	0.89	0.11	0.19	75
df	0.06	0.17	0.09	6
mel	0.30	0.15	0.20	39
nv	0.90	0.95	0.92	751
vasc	0.69	0.82	0.75	11
total	0.84	0.82	0.80	938

Tabla 5.1: Resumen de la ejecución de los datos de entrenamiento

El rendimiento del modelo se muestra en la Figura 5.1.

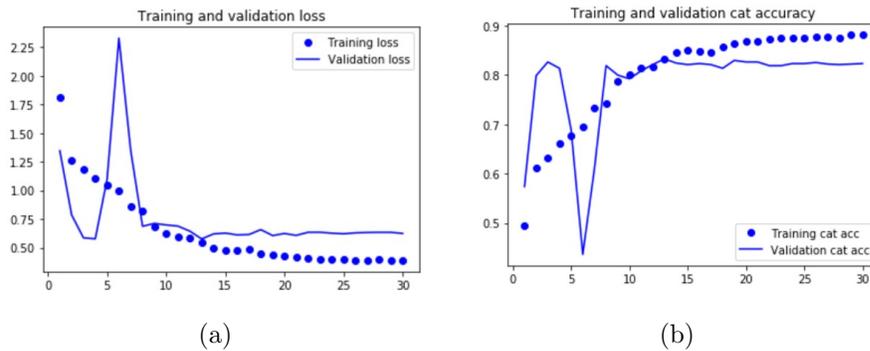


Figura 5.1: Curvas de entrenamiento

Se puede observar en la figura 5.2 que nuestro modelo tiene un rendimiento aceptable y un número significativo de pruebas para la clase nv (nevus melanocíticos) se clasificaron correctamente. El modelo predice su mayoría de las clases akiec, bcc, bkl, nv, y vasc correctamente, pero lucha con df(dermatofibroma).

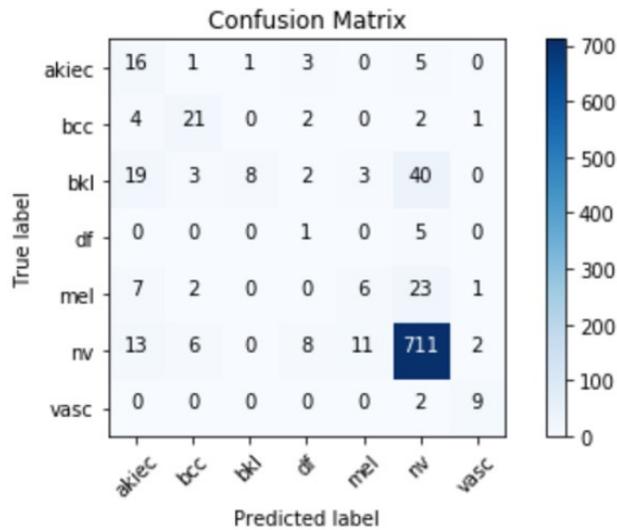


Figura 5.2: Matriz de confusión

5.2. Experimento II

El cáncer de piel es la neoplasia maligna humana más común, se diagnostica principalmente de forma visual, comenzando con un examen clínico inicial y seguido potencialmente por un análisis dermatoscópico, una biopsia y examen histopatológico. La clasificación automatizada de las lesiones cutáneas mediante imágenes es una tarea difícil debido a la variabilidad en la apariencia de las lesiones cutáneas.

Se presenta el diseño de una red neuronal convolucional para detectar 7 principales tipos de cáncer de piel usando la red neuronal convolucional con keras y tensorflow y se analizó el resultado para ver como el modelo puede ser útil y práctico para obtener la clasificación como se muestra en la siguiente figura 5.3.

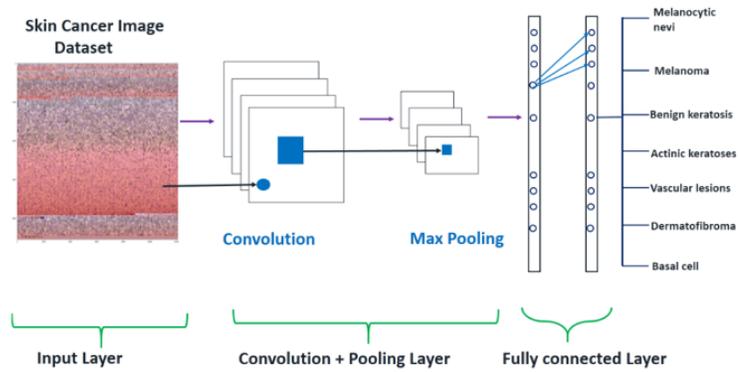


Figura 5.3: Estructura de la red

5.2.1. Características de las imágenes

Se visualizaron las diferentes clases del conjunto de datos, sus distribuciones y conteos reales.

En la figura 5.4 donde se puede apreciar que en el conjunto de datos los nevos melanocíticos tienen un número muy grande de casos en comparación con otros tipos de células.

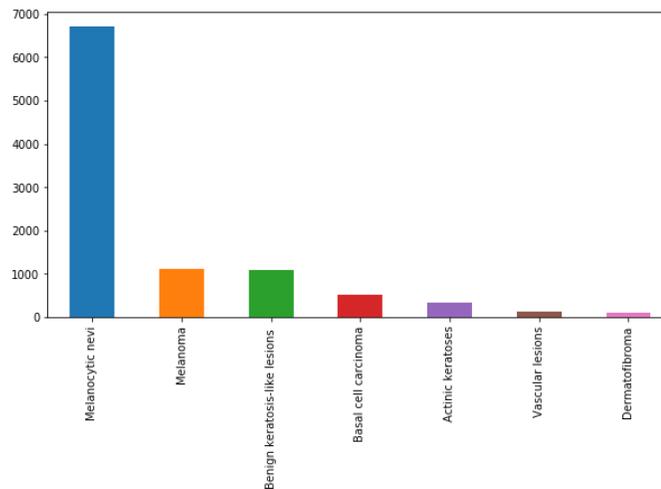


Figura 5.4: Representación de las clases

En la siguiente gráfica que se muestra en la figura 5.5 se pueden observar como se distribuyen en sus 3 categorías que se explican a continuación:

- Histopatología (Histo): los diagnósticos histopatológicos de las lesiones extirpadas han sido realizados por dermatólogos especializados.
- Confocal: la microscopía confocal de reflectancia es una técnica de imagen in vivo con una resolución a nivel casi celular, y algo facial benigno con un supuesto del mundo gris de todas las imágenes del conjunto de entrenamiento en el espacio de color Lab antes y después de los cambios manuales del histograma.
- Consenso: para casos benignos típicos sin histopatología o biólogos de seguimiento, proporcione una calificación de consenso de expertos de los autores PT y HK. Aplicaron la etiqueta de consenso solo si ambos autores dieron de forma independiente el mismo diagnóstico inequívoco benigno. Las lesiones con este tipo de verdad básica generalmente se fotografiaban por razones educativas y no necesitaban más seguimiento o biopsia para su confirmación.

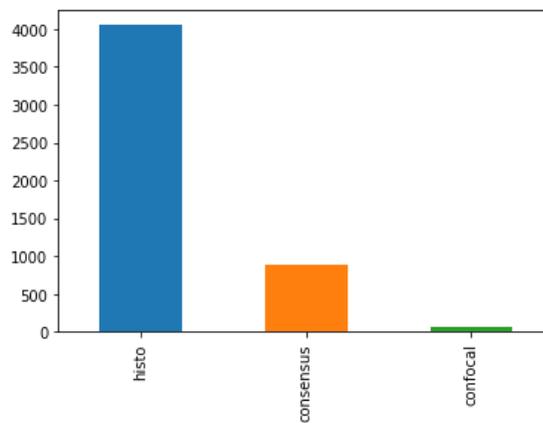


Figura 5.5: Tipo de categoría

Se gráfico el campo de localización en donde es que observan las diferentes lesiones cutáneas y se pudo observar que la parte posterior, la extremidad inferior, el tronco

y la extremidad superior son regiones muy comprometidas de cáncer de piel como se muestra en la figura 5.6.

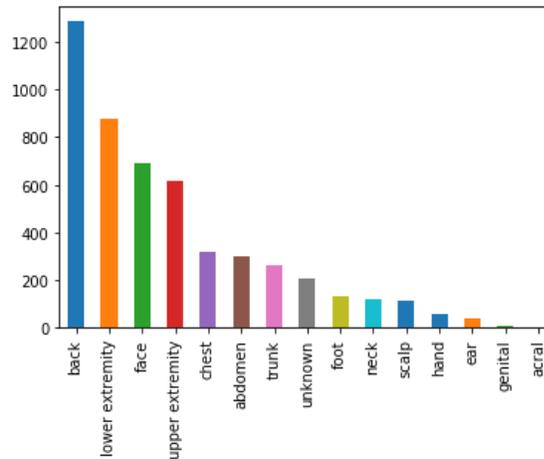


Figura 5.6: Localización de las lesiones cutáneas

Se gráfico los diferentes casos que hay de hombres y mujeres de y se pudo observar que hay mas casos de hombres que de mujeres como se muestra en la siguiente figura 5.7.

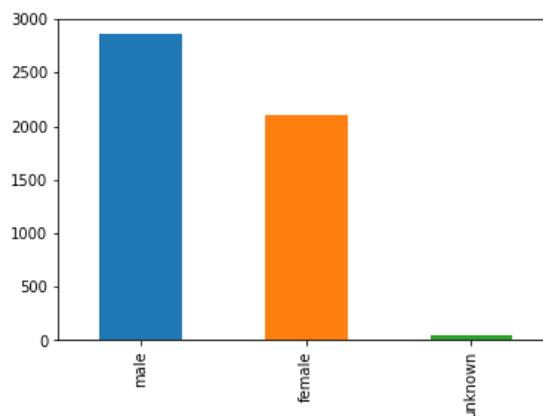


Figura 5.7: Distribución de mujeres y hombres

En la siguiente figura 5.8 se puede observar cómo varían las muestras de color normalizadas a través de los diferentes tipos de enfermedades de la piel.

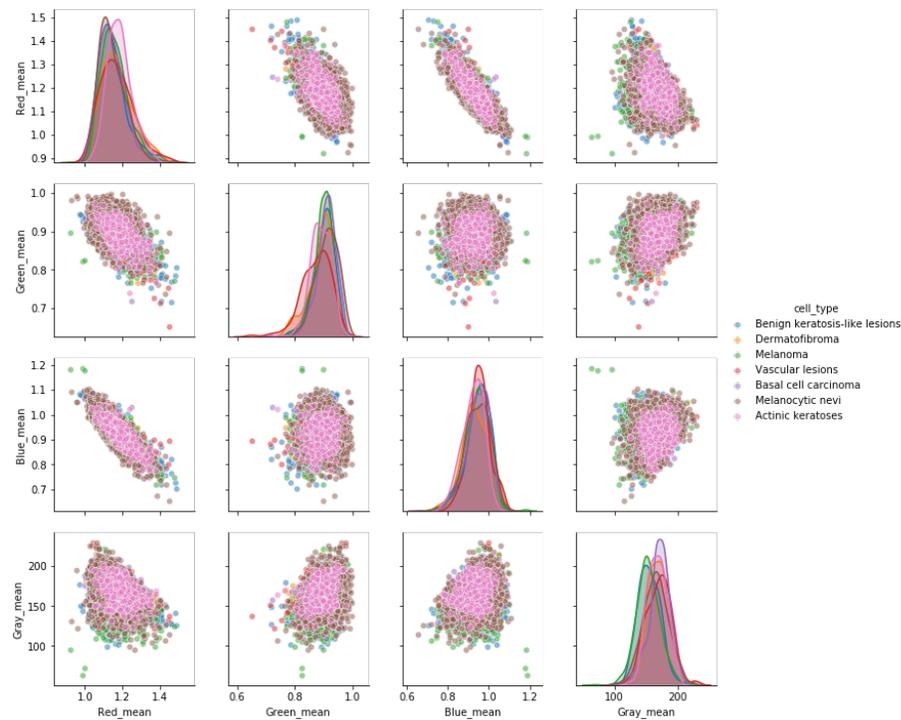


Figura 5.8: Análisis de canal de color

5.2.2. Modelo de red

Para obtener los resultados se dividieron los datos en 75% el conjunto de entrenamiento y el conjunto de datos de prueba contiene el 25%. Se Capacito el modelo en el conjunto de datos de entrenamiento para un total de 24 épocas, se verifico la precisión de las pruebas y la precisión de validación del modelo como se muestra en la figura 5.9

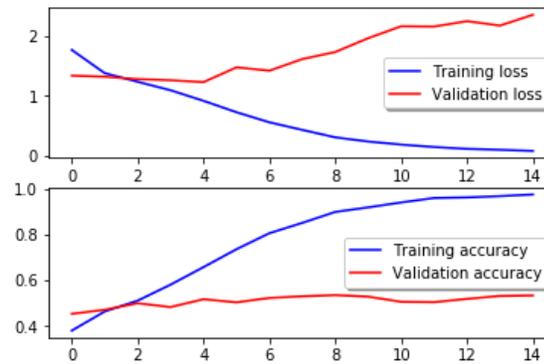


Figura 5.9: Curvas de entrenamiento

Se puede observar en la figura 5.10 que el modelo tiene un número máximo de predicciones incorrectas para el carcinoma de células basales que tiene el número 3, luego el segundo tipo más mal clasificado es el número 5 de lesiones vasculares y luego el número 0 de nevos melanocíticos, mientras que el número 4 de queratosis actínica tiene el tipo menos mal clasificado y nos dio un resultado de clasificación del 65% .

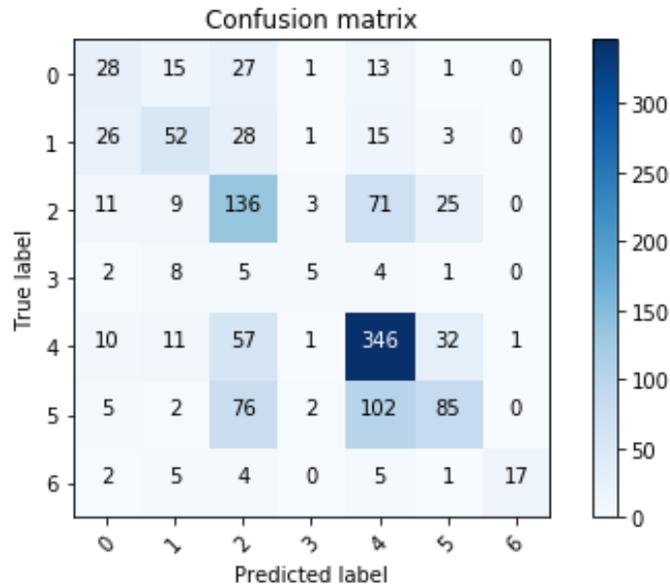


Figura 5.10: Matriz de confusión

Capítulo 6

Conclusiones y trabajo a futuro

6.1. Conclusiones

Se demostró que el aprendizaje profundo resulta aceptable en la categorización de anormalidades cancerígenas, esto puede llegar a ser una contribución al especialista médico, para ser un apoyo en la interpretación de las imágenes, al mismo tiempo, esto permite contribuir en el desarrollo tecnológico y social en beneficio de pacientes. Sin duda alguna la inteligencia artificial representa una revolución tecnológica en la actualidad y siendo el aprendizaje automático una de las vertientes de esta se puede decir que está a la vanguardia. Ya que aplicando aprendizaje automático y sus distintos algoritmos de clasificación se puede ayudar al mejoramiento de la calidad de vida que existe hasta estos momentos y así se puede atender de forma inmediata y así aplicar el tratamiento más indicado que recomiende el médico. En este trabajo, se analizaron dos redes la primera fue una red neuronal convolucional simple y la segunda se utilizó el modelo MobileNet con ella se clasificaron siete tipos de lesiones de la piel de imágenes dermoscópicas utilizando el conjunto de datos HAM10000, que se usó para capacitar y validar las redes mencionadas. Los resultados obtenidos fueron los siguientes: en la primera red obtuvo un resultado del 56% y la segunda utilizando la arquitectura MobileNet obtuvo un resultado de 84%.

6.2. Trabajo a futuro

Como trabajo futuro se pretende mejorar los resultados obtenidos en esta investigación.

- Una posible mejora de robustez para el modelo de entrenamiento de la arquitectura MobileNet para que se obtenga un mejor resultado.
- Utilizar otros enfoques de aprendizaje profundo

- Explorar otras arquitecturas de aprendizaje profundo que sean mas exibles de entrenar y que podr'ian proporcionar una interpretabilidad aún más concreta.
- Utilizar un dataset de la región.
- Utilizar un nuevo entorno de programación que pudiera ayudar a desarrollar un proyecto de mejor calidad y precisión.

Bibliografía

- [1] Instituto Nacional de Estadística. Geografía e Informática. (2007). Estadísticas a propósito del día mundial contra el cáncer.
- [2] Vidrio, R. M. G. (2003). Cancer of the skin. Revista de la Facultad de Medicina UNAM, 46(4), 166-171.
- [3] SINAIS/SINAVE/DGE/SALUD/Perfil epidemiológico de los tumores malignos en México. México: 2011; 45.
- [4] Formación, D., Tecnologías, B., Web, P., Data?, ¿. (2020). ¿Qué son los datasets y los dataframes en el Big Data? — Deusto Formación. Retrieved 26 June 2020, from <https://www.deustoformacion.com/blog/programacion-diseno-web/que-son-datasets-dataframes-bigdata#:~:text=Un%20conjunto%20de%20datos%20o,de%20datos%20que%20estamos%20tratndo> .
- [5] 2.6. Manipulación y procesamiento de imágenes usando Numpy y Scipy — Scipy lecture notes. (2020). Retrieved 29 June 2020, from https://claudiovz.github.io/scipy-lecture-notes-ES/advanced/image_processing/index.html
- [6] Lundh, F., Ellis, M. (2002). Python Imaging Library Overview. PIL, 1(3), 77.
- [7] Braccini, C., DeFloriani, L., Vernazza, G. (1995). Image analysis and processing. Berlin: Springer-Verlag.

-
- [8] El color es luz :<http://proyectacolor.cl/teoria-de-los-colores/el-color-es-luz/>.
- [9] Rastislav Lukac. Computational photography - Pag. 104-106.
- [10] Espectro de Luz Visible ESPECTRO de LUZ IMÁGENES RAN- GO . (2020). Retrieved 28 June 2020, from <https://fotomanias.com.ar/espectro-de-luz-visible/>
- [11] Valdés-Rodríguez, R., Torres-Álvarez, B., González-Muro, J., y Almeda-Valdés, P. (2012). La piel y el sistema endocrinológico. Gaceta médica de México, 148(2), 162-168.
- [12] Stanfordchildrens.org. (2019). default - Stanford Children's Health. [online] Available at: <https://www.stanfordchildrens.org/es/topic/default?id=anatomadelapiel-85-P04436> [Accessed 27 Feb. 2019].
- [13] Faizal, M. (1995). Cáncer de piel. Revista de la Facultad de Medicina, 43(3), 138-142.
- [14] Duce, Martín. Patología quirúrgica. Editorial Elsevier España; 2004.
- [15] AP, 2. (2020). USO DEL DERMATOSCOPIO EN AP - Dermatologia en Pri- maria Camfic. Retrieved 29 June 2020, from <http://dermatoscopia.camfic.cat/2016/11/24/uso-del-dermatoscopio-en-ap/>
- [16] Aurélien Géron. (March 2017). The Fundamentals of Machine Learning. En Hands-On Machine Learning with Scikit-Learn and TensorFlow(1-718). Printed in the United States of America.: O'Reilly Media, Inc., 1005 Gravenstein Highway North, Sebastopol, CA 95472.
- [17] R. Collobert, (2011), "Deep Learning for Efficient Discriminative Pars ing,"

- [18] Neural networks : algorithms, applications, and programming techniques / James A. Freeman, David M. Skapura
- [19] Curso CS231n de la universidad de Stanford - Redes neuronales convolucionales para el reconocimiento visual - Módulo 1 [Online]. Disponible: <http://cs231n.github.io>.
- [20] Formación, D., Tecnologías, B., Web, P., Data?, J. (2020). ¿Qué son los datasets y los dataframes en el Big Data? — Deusto Formación. Retrieved 26 June 2020, from <https://www.deustoformacion.com/blog/programacion-diseno-web/que-son-datasets-dataframes-big-data#:~:text=Un%20conjunto%20de%20datos%20o,de%20datos%20que%20estamos%20tratando> .
- [21] 0Mathworks.com. (2019). What Is Machine Learning? — How It Works, Techniques Applications. [online] Available at: <https://www.mathworks.com/discovery/machine-learning.html> [Accessed 27 Feb. 2019].
- [22] Salas, R. (2004). Redes neuronales artificiales. Universidad de Valparaíso. Departamento de Computación, 1.
- [23] Hijazi, S., Kumar, R., Rowen, C. (2015). Using convolutional neural networks for image recognition. Cadence Design Systems Inc.: San Jose, CA, USA.
- [24] Diego Calvo. (2019). Clasificación de redes neuronales artificiales - Diego Calvo. [online] Available at: <http://www.diegocalvo.es/clasificacion-de-redes-neuronales-artificiales/> [Accessed 27 Feb. 2019].
- [25] Coto, E. (2003). Métodos de segmentación de imágenes médicas. Universidad Central de Venezuela: Lecturas en Ciencias de la Computación, 1, 9-15.

- [26] Hall, M. A. and Smith, L. A. (1997). Feature subset selection: a correlation based filter approach. pages 855–858.
- [27] Kira, K. and Rendell, L. A. (1992a). The feature selection problem: Traditional methods and a new algorithm. In AAAI, pages 129–134
- [28] K, Alexander Mordvintsev A. Open Source Computer Vision. 2013
- [29] Liu, H. and Yu, L. (2005). Toward integrating feature selection algorithms for classification and clustering. Knowledge and Data Engineering, IEEE Transactions
- [30] j.amatrodriago@gmail.com, J. (2020). Análisis discriminante lineal (LDA) y análisis discriminante cuadrático (QDA). Retrieved 29 June 2020, from https://www.cienciadedatos.net/documentos/28_linear_discriminant_analysis_lda_y_quadratic_discriminant_analysis_qda#:~:text=An%C3%A1lisis%20discriminante%20lineal-,Idea%20intuitiva,en%20funci%C3%B3n%20de%20sus%20caracter%C3%ADsticas
- [31] j.amatrodriago@gmail.com, J. (2020) Análisis de Componentes Principales (Principal Component Analysis, PCA) y t-SNE. Retrieved 29 June 2020, from https://www.cienciadedatos.net/documentos/35_principal_component_analysis
- [32] Raschka, S. (2017). Python machine learning, second edition. Birmingham: Packt Publishing.
- [33] Lakshay Bajaj, Himanshu Kumar, Yasha Hasija. Automated System for Prediction of Skin Disease using Image Processing and Machine Learning. International Journal of Computer Applications (0975 – 8887) Volume 180 – No.19, February 2018.

-
- [34] Uzma Bano Ansari and Tanuja Sarode. Skin Cancer Detection Using Image Processing. *International Research Journal of Engineering and Technology (IRJET)*. April 2017.
- [35] Garg, C., y Bhadauria, M. (2015). An Analysis of Skin Cancer Detection Using Imagery Techniques (2010-2015). *International Journal*, 5(10).
- [36] R., S., Gound, Priyanka, S., Gadre, Jyoti, B., Gaikwad, y Priyanka K. Wagh. (2018). Skin Disease Diagnosis System using Image Processing and Data Mining. *International Journal of Computer Applications*, (179 – No.16), 38-40.
- [37] Li , Y., and Shen, L. Skin lesion analysis towards melanoma detection using deep learning network. *Sensors* 18, 2 (2018), 556.
- [38] Lau, H. T., y Al-Jumaily, A. (2009, December). Automatically early detection of skin cancer: Study based on nueral netwok classification. In *Soft Computing and Pattern Recognition, 2009. SOCPAR'09. International Conference of* (pp. 375-380). IEEE.
- [39] GoDorj, U. O., Lee, K. K., Choi, J. Y., y Lee, M. (2018). The skin cancer classification using deep convolucional neural network. *Multimedia Tools and Applications*, 1-16.
- [40] Singhal, E., y Tiwari, S. (2015). Skin Cancer Detection using Arificial Neural Network. *International Journal of Advanced Research in Computer Science*, 6(1).
- [41] Mhaske, H. R., y Phalke, D. A. (2013, December). Melanoma skin cancer detection and classification based on supervised and unsupervised learning. In *Circuits, Controls and Communications (CCUBE), 2013 International conference on* (pp. 1-5). IEEE.

-
- [42] Registro histopatológico de las neoplasias malignas. Compendio de Cáncer. Secretaría de Salud 2001, México.
- [43] Dirección General de Información de Salud. Sistema Nacional de Información de Salud (SINAIS). Perfil epidemiológico de los tumores malignos en México, 2011.
- [44] Lau, H. T., y Al-Jumaily, A. (2009, December). Automatically early detection of skin cancer: Study based on neural network classification. In *Soft Computing and Pattern Recognition, 2009. SOCPAR'09. International Conference of* (pp. 375-380). IEEE.
- [45] Rojas, R. (2013). *Neural networks: a systematic introduction*. Springer Science y Business Media.
- [46] Lopez, A. R., Giro-i-Nieto, X., Burdick, J., and Marques, O. (2017, February). Skin lesion classification from dermoscopic images using deep learning techniques. In *2017 13th IASTED International Conference on Biomedical Engineering (BioMed)* (pp. 49-54). IEEE.
- [47] Milton, M. A. A. (2019). Automated Skin Lesion Classification Using Ensemble of Deep Neural Networks in ISIC 2018: Skin Lesion Analysis Towards Melanoma Detection Challenge. arXiv preprint arXiv:1901.10802.
- [48] Tschandl, P. (2018). The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions.
- [49] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. arXiv preprint arXiv:1704.04861.
- [50] R. C. González and R. E. Woods, *Tratamiento digital de imágenes*. Addison-Wesley Iberoamericana, S.A., Ediciones Díaz de Santos, S.A, 1996.