



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MÉXICO

CENTRO UNIVERSITARIO UAEM TEXCOCO

**SISTEMA DE PRE-DIAGNÓSTICO DE CÁNCER DE MELANOMAS USANDO
REDES NEURONALES ARTIFICIALES**

T E S I S

**QUE PARA OBTENER EL GRADO DE:
LICENCIADO EN INFORMÁTICA ADMINISTRATIVA**

PRESENTA:

DULCE CHARIN VENEGAS FLORES

DIRECTOR:

DR. EN I. S. JOSÉ SERGIO RUIZ CASTILLA

REVISORES

DR. ADRIAN TRUEBA ESPINOSA

DR. EN C. JAIR CERVANTES CANALES

TEXCOCO, ESTADO DE MÉXICO, MARZO 2019



Universidad Autónoma del Estado de México

UAEM

Texcoco, Méx. a 27 de noviembre de 2018.

Asunto: Etapa de digitalización

M. EN C. ED. VIRIDIANA BANDA ARZATE
SUBDIRECCION ACADEMICA DEL
CENTRO UNIVERSITARIO UAEM TEXCOCO
P R E S E N T E.

AT'N: L. EN I. A. CINTHYA TERESITA ISLAS RODRIGUEZ
RESPONSABLE DEL DEPARTAMENTO DE TITULACIÓN

Con base en las revisiones efectuadas al trabajo escrito titulado "Sistema de Pre-diagnóstico de Cáncer en Melanomas Usando Redes Neuronales Artificiales" que para tener el título de la Licenciatura en **Informática Administrativa** presenta la sustentante **Dulce Charín Venegas Flores** con el número de cuenta **1325398**, se concluye que cumple con los requisitos teórico-metodológico por lo que se otorga el voto aprobatorio para su sustentación, pudiendo **continuar con la etapa de digitalización** del trabajo escrito

A T E N T A M E N T E


DR. EN C. ADRIAN TRUEBA ESPINOSA
REVISOR


DR. EN C. JAIR CERVANTES CANALES
REVISOR


DR. EN I. S. JOSÉ SÉRGIO RUIZ CASTILLA
Director



c.c.p. Sustentante: DULCE CHARIN VENEGAS FLORES
c.c.p. Asesor de Tesis: DR. EN I. S. JOSÉ SÉRGIO RUIZ CASTILLA
c.c.p. Titulación: L. EN I. ELYN RAMOS CUEVAS

Centro Universitario UAEM Texcoco
Av. Jardín Zumpango s/n. Fracc. El Tejacote
C. P. 56259 Texcoco, Estado de México
Tels. (595) 9211216- 9211247- 9210368- 9210493

CUTex

Índice

Capítulo I . Introducción.....	1
1.1 Introducción	1
1.2 Justificación	2
1.3 Planteamiento del problema.....	4
1.4 Delimitación del Problema	7
1.5 Objetivos.....	8
1.5.1. Objetivo General	8
1.5.2 Objetivos Específicos.....	8
1.7 Hipótesis	9
Capítulo II . Marco Teórico.....	10
2.1 Matlab	10
2.2 Python	12
2.3 Jupyter.....	13
2.4 Sistema.....	14
2.5 Segmentación	14
2.6 Imagen	14
2.7 Pixel	15

2.8 Resolución de Imagen.....	16
2.9 Profundidad de Color.....	16
2.10 Modelos de Color.....	17
a) Modo monocromático.....	17
c) Modo Color indexado	18
e) HSV	20
2.11 Formatos de imagen.....	21
2.11.1 BMP (Bitmap = Mapa de bits). [14]	21
2.11.2 GIF (Graphics Interchange Format = Formato de Intercambio Gráfico). [14] ..	21
2.11.3 JPG-JPEG (Joint Photographic Experts Group = Grupo de Expertos Fotográficos Unidos). [14]	22
2.11.4 TIF-TIFF (Tagged Image File Format = Formato de Archivo de Imagen Etiquetada). Almacena imágenes de una calidad excelente. [14].	23
2.11.5 PNG (Portable Network Graphic = Gráfico portable para la red). [14].....	23
2.12 Procesamiento de Imágenes.....	23
2.13 Redes Neuronales Artificiales	24
2.13.1 El elemento receptor.....	25
2.13.2 El elemento sumador.....	25
2.13.3 El elemento de función activadora.....	25
2.13.4 El elemento de salida.....	25

2.14 Ventajas que ofrecen las redes neuronales.....	26
2.14.1 Aprendizaje adaptativo.....	26
2.14.2 Auto-organización.....	26
2.14.3 Tolerancia a fallos	27
2.14.4 Operación en tiempo real	27
2.15 Perceptrón	28
2.15.1 Arquitectura del Perceptrón	28
2.15.2 Aprendizaje del perceptrón	29
2.16 Red Neuronal Convolutiva.....	30
2.16.1 Capa Convolutiva	31
2.16.2 Capa Pooling	31
2.17 Red Neuronal Backpropagation.....	33
2.17.1 Aprendizaje de Backpropagation	34
2.18 Irradiancia Solar.....	35
2.18.1 Radiación solar directa y difusa	35
2.18.2 Tipos de Radiación.....	36
2.19 Dermatólogo	38
2.20 Tipos de Piel	38
2.20.1 Fototipo	39
2.21 Oncólogo.....	40

2.22 Cáncer	41
2.23 Tumor.....	41
2.24 Melanoma	41
2.24.1 Señales de alarma de melanomas	42
2.25 Carcinoma.....	43
2.26 Cáncer de Piel (Cáncer Cutáneo).....	44
2.27 Lunares.....	45
Capítulo III Metodología.....	46
3.1 Recopilación de imágenes y metadatos de melanomas malignos y benignos	46
3.2 Red Neuronal tipo Perceptrón con metadatos.....	48
3.2.1 Método de la clasificación de los atributos encontrados en la base de datos de la página web <i>Archivo ISIC</i>	48
3.2.2 Entrenamiento del Perceptrón con Metadatos.....	50
3.2.3 Prueba del Perceptrón con Metadatos	52
3.3 Backpropagation con Metadatos.....	53
3.3.1 Valores Iniciales.....	53
3.3.2 Entrenamiento de la Red Neuronal Backpropagation con metadatos	54
3.3.3 Prueba.....	55
3.4 Red Neuronal Convolutiva con imágenes.....	56
3.4.2 Creación de los directorios para la Red Convolutiva	56

3.4.3 Algoritmo para la Red Neuronal Convolutacional.....	57
3.4.4 Entrenamiento de la Red Neurona Convolutacional.....	59
3.4.5 Prueba.....	61
Capítulo IV Resultados y Conclusiones	65
4.1 Resultados	65
4.1.1 Red Neuronal Perceptrón con Metadatos.....	65
4.1.2 Red Neuronal Backpropagation con metadatos	68
4.1.3 Red Neuronal Convolutacional.....	71
4.2 Conclusiones.....	73
4.2.1 Red Neuronal Perceptrón con metadatos	73
4.2.2 Red Neuronal Backpropagation con metadatos	73
4.2.3 Red Neuronal Convolutacional con imágenes	74
Capítulo V Referencias.....	75

Índice de Figuras

Figura 1. Fotoenvejecimiento cutáneo; por exposición solar crónica en un jugador de golf (efecto crónico). [3]	5
Figura 2. Logo de Matlab.org.....	10
Figura 3. Logotipo de Python.org.....	12
Figura 4. Logo de Jupyter.org [9].....	14
Figura 5. Si aplicamos el zoom sobre ella observaremos que está formada por una parrilla de puntos o píxeles como se muestra en la ilustración. [16]	16
Figura 6. Imagen modo monocromático. [14].....	17
Figura 7. Imagen modo Escala de Gises. [14].....	18
Figura 8. Imagen modo Color indexado. [14]	18
Figura 9. Imagen modo RGB. [14].....	19
Figura 10. Espacio de Colores RGB [13].....	19
Figura 11. Paleta de colores HSV. [14].....	20
Figura 12. Comparación de imágenes en modo RGB y CMYK. [14]	21
Figura 13. Esquema de neurona artificial. [19]	26
Figura 14. Una unidad de lógica de umbral [21].....	28
Figura 15. Arquitectura Original del Perceptrón [21]	29
Figura 16. Esquema básico de una Red Neuronal Convolutacional. [22].....	30
Figura 17. Proceso de la capa pooling. [23]	33
Figura 18. Difusión de la luz solar directa. [3].....	36
Figura 19. Radiación solar difusa. [3]	36
Figura 20. Fototipo. [25]	39

Figura 21. Señales de alarma de melanoma. [25].....	42
Figura 22. Anatomía de la piel que muestra la epidermis y la dermis. Los melanocitos están en la capa de células basales, en la parte más profunda de la epidermis. [28]	43
Figura 23. Anatomía de la Piel. Muestra la epidermis, la dermis y el tejido subcutáneo. [28]	44
Figura 24. Banco de Imágenes de melanomas de Archivo ISIC. (https://isic-archive.com).	46
Figura 25. Página de Inicio de Archivo ISIC (https://www.isic-archive.com/#!/topWithHeader/onlyHeaderTop/gallery).....	47
Figura 26. Base de Datos de cada melanoma (https://isic-archive.com/#images).	47
Figura 27. Descarga de las imágenes de melanomas en dos archivos .rar (malignos y benignos).	48
Figura 28. Contenido de la carpeta DataCMC.	56
Figura 29. Contenido de la carpeta Benignos.....	57
Figura 30. Archivo Modelo.H5 y Peso.H5.....	61
Figura 31. Gráfica del entrenamiento del perceptrón con metadatos.	65
Figura 32. Gráfica de la prueba del perceptrón con metadatos.	66
Figura 33. Gráfica linealmente separable del perceptrón con metadatos utilizando los datos de la prueba (perceptrón cruzado).	67
Figura 34. Gráfica linealmente separable del perceptrón con metadatos utilizando los datos del entrenamiento (perceptrón cruzado).	68
Figura 35. Impresión de pantalla de la ventana de comandos de Matlab.	69
Figura 36. Margen de Error del Backpropagation con metadatos.	69
Figura 37. Gráfica de clasificación de la red neuronal Backpropagation con metadatos.....	70

Índice de Tablas

Tabla 1 Niveles de las unidades médicas en México [1].....	2
Tabla 2. Posibles Escenarios en enfermedades de piel.....	4
Tabla 3. Tipos de radiaciones según su longitud de onda. [3].....	37
Tabla 4. Tipos de radiaciones infrarrojas según su longitud de onda. [3].....	37
Tabla 5. Clasificación en los atributos de los metadatos sacados de la página web ISIC.	48
Tabla 6. Metadatos normalizados ordenadas en 2 filas separadas por ";". La primera fila es tamaño y segunda fila es tipo.	50
Tabla 7. Matriz de Prueba con 40 datos sacados de ISIC.....	52
Tabla 8. 80 metadatos de entrenamiento de los 2 atributos, tamaño y tipo en donde 40 son malignos y 40 benignos.	53
Tabla 9. Tabla de Resultado del Pre- diagnóstico.	71
Tabla 10. Resultado de la compilación de la red Neuronal Convolucional	72
Tabla 11. Comparación del porcentaje de eficiencia de cada Red Neuronal	73

Índice de Códigos

Código 1. Indicación de la separación en los 42 melanomas.	51
Código 2. Entrenamiento del perceptrón con metadatos de ISIC.....	51
Código 3. Lee la matriz de la nueva variable p y clasifica según el entrenamiento al que ya fue introducido.....	52
Código 4. Numero de neuronas en la capa oculta.	54
Código 5. Ventana de valores iniciales.	54
Código 6. Valores iniciales de los pesos sinápticos.	54
Código 7. Propagación de la entrada hacia la salida.	54
Código 8. Retropropagación de la sensibilidad.	55
Código 9. Ciclo de reconocimiento de patrones.....	55
Código 10. Librerías para la Red Neuronal Convolucional.	57
Código 11. Cargar imágenes desde el directorio.....	58
Código 12. Determinación de los parámetros.	58
Código 13. Función ImageDataGenerator() y Batch_size para preparar las imágenes.....	59
Código 14. Algoritmo de aprendizaje de la Red Neuronal Convolucional.....	60
Código 15. Algoritmo de almacenamiento para reconocimiento de archivos.....	60
Código 16. Algoritmo de predicción del pre-diagnóstico.	61
Código 17. Impresión del pre-diagnóstico.	62

Capítulo I . **Introducción.**

1.1 Introducción

Mientras nuestro cuerpo se desarrolla, va adquiriendo señas particulares, que dan una identidad. Esto, nos hace identificables dentro del entorno sociocultural, a partir de rasgos particulares como: el color de piel, ojos, cicatrices, lunares, etc.; una simpática percepción al reconocimiento visual. Sin embargo, no sabemos si estas marcas pueden causar algún problema más tarde en nuestra salud.

En este sentido, se propone el desarrollo de un sistema de pre-diagnóstico para cáncer de piel, que se delimitara específicamente en lunares (médicamente conocido como melanomas). El sistema se formara con un algoritmo de Redes neuronales artificiales, obteniendo una respuesta elevada en la predicción, en base a la colección de imágenes almacenadas, donde serán clasificadas según su carácter (como benigno o maligno). Ya que, las redes neuronales seleccionan y otorgan el pre-diagnóstico resultando como positivo o negativo.

De esta manera, se busca apoyar al sistema de salud mexicano en lugares donde las clínicas no tengan los materiales profesionales necesarios y/o posibilidades financieras para contratar a un especialista. Teniendo como resultado que el médico de las clínicas, sin la necesidad de ser un especialista en el área dermatológica u oncología, pre-diagnosticará al paciente. Otorgando una gran oportunidad a las poblaciones con recursos bajos a mantener un cierto cuidado en la piel y prevenir futuras enfermedades.

1.2 Justificación

El sistema beneficiará a médicos que trabajen en regiones rurales para usarlo en los pacientes de la localidad, ya que se trata de implementar esta herramienta de pre-diagnóstico de cáncer en la piel con un costo bajo, y sea colocada fácilmente en clínicas rurales. Con la finalidad de, ayudar a que los pobladores que no tengan los recursos necesarios para viajar a ciudades lejanas, donde existan hospitales de 3° nivel, no gasten cantidades grandes en traslado, transporte, consultas, etc., solo para obtener un diagnóstico que pueda ser facialmente determinado en su región. Ver Tabla 1.

Tabla 1 Niveles de las unidades médicas en México [1]

Nivel	Centros	Descripción
<i>Primer Nivel</i>	Lo constituyen las Unidades de Medicina Familiar (IMSS), Centros de Salud (SSa) y Clínicas Familiares (ISSSTE).	Proporcionan los servicios de salud básicos. Son el principal escenario de la salud preventiva y es el nivel en donde se atiende y resuelve 80% de los padecimientos.
<i>Segundo Nivel</i>	Corresponde a los Hospitales Generales, Regionales, Integrales, Comunitarios; también a los Hospitales Pediátricos, de Gineco-Obstetricia o Materno-Infantiles, así como los Hospitales Federales de Referencia que se localizan en la Ciudad de México.	Cuando la enfermedad presenta manifestaciones físicas que realice un tratamiento para limitar el daño y recuperar la salud. Para ello se recurre a la internación, al tratamiento quirúrgico o clínico específico.
<i>Tercer nivel</i>	Son los Centros Médicos Nacionales (CMN), Unidades Médicas de Alta Especialidad (Umaes), los Institutos Nacionales de Salud, que se concentran en su mayoría en la Ciudad de México, y los Hospitales Regionales de Alta Especialidad, de los cuales existen actualmente seis en distintas regiones del país.	Es la red de hospitales de alta especialidad con avanzada tecnología. Se tratan enfermedades de baja prevalencia, de alto riesgo y las enfermedades más complejas. En ellos se atiende a los pacientes que remiten los hospitales de segundo nivel.

El sistema para pre-diagnóstico de cáncer en lunares permite obtener un pronóstico del melanoma sin la necesidad de ser un especialista en dermatología u oncología. Asimismo, el algoritmo de aprendizaje de redes neuronales artificiales determinará si un lunar es benigno o maligno (cancerígeno) usando el reconocimiento de imágenes mientras clasifica el estado de la imagen, dando como resultado el <<Pre-diagnóstico>>.

El proceso, ayudará a que la población adquiera hábitos al cuidado cutáneo y tenga el seguimiento correcto en el cuidado de la piel, dando el caso que los pacientes que obtengan resultados negativos inmediatamente seguirán con el tratamiento correspondiente.

1.3 Planteamiento del problema

En pequeñas poblaciones mexicanas se tienen escasos recursos en muchos sectores; tanto en tecnología, cultura, educación, salud, etc., y carecen de servicios básicos extremadamente necesarios como asistencia médica. Pues bien, muchos de los poblados marginados no cuentan con los recursos necesarios para clínicas de Salud, esto ocasiona que tengan que emigrar por un corto tiempo a poblaciones de grandes ciudades en donde cuenten con hospitales de 2° y/o 3° nivel que cubran con los recursos necesarios para sus padecimientos.

Esto, afecta no solo en el tiempo del traslado para llegar al lugar, también, daña la salud del paciente, según el tiempo de respuesta en atender su malestar, causando bajas en el capital del paciente, en aspectos como: gastos de transporte, hospitalarios, alimentos, hospedajes, etc., es decir, incrementando la pobreza en su vivienda por un servicio que no se obtiene en su entidad federativa. Ver Tabla 2.

Tabla 2. Posibles Escenarios en enfermedades de piel.

Factores	Principales Causas	Razón
<i>Herencia</i>	Genética Cancerígena Familiar	Las personas que algún tipo de cáncer de piel puede heredar el mismo mal a sus futuras generaciones.
<i>Patología</i>	Sistema inmunitario débil	Por alguna enfermedad microbiana que cause la debilidad del sistema inmune hace que sea más propenso a enfermedades cancerígenas de cualquier tipo.
<i>Ambiental</i>	Radiación solar	Los rayos infrarrojos, rayos ultravioleta, etc., causadas por el sol perjudican a la epidermis, dañando a las demás capas de la piel, ocasionando el cáncer.
<i>Edad</i>	Vejez	Ya que las células no se regeneran tan rápido como en los niños y en el caso de la piel en las personas de edad avanzada es vulnerable al cáncer.
<i>Tabaquismo</i>	Consumo masivo en cigarros	El tabaquismo es uno de los principales portadores de cualquier tipo de cáncer. Entre ellos se encuentra el cáncer de piel

Sin embargo, existen en poblados más afortunados pequeñas clínicas rurales en donde, solo cuentan con un médico y una enfermera. Estos, no cuentan con la capacitación adecuada en las diferentes áreas de la medicina; e incluso en lo tecnológico, no se tienen las herramientas fundamentales para las diversas situaciones médicas, sin mencionar la falta de transporte para el traslado emergente de pacientes.

Por otra parte, hoy en día, la radiación solar ha incrementado potencialmente en la última década por diversos factores ambientales; intensificando problemas en la piel, ocasionando los siguientes males:

- Fotoenvejecimiento cutáneo¹. Ver Figura 1.
- Fotocarcinogénesis².
- Quemadura solar (de primer grado o enrojecimiento, segundo grado con ampollas).
- Insolaciones, etc., [2].

Afectando a la población mexicana que trabaja arduamente en regiones muy soleadas, sin la protección solar adecuada, arriesgando la piel a las enfermedades ya mencionadas.



Figura 1. Fotoenvejecimiento cutáneo; por exposición solar crónica en un jugador de golf (efecto crónico). [3]

¹ Envejecimiento prematuro de la piel que implica dilatación vascular, arrugas y manchas. [2]

² Aparición de tumores cutáneos. [2]

Se plantea la siguiente pregunta de investigación ¿Cómo hacer un pre-diagnóstico de cáncer en melanomas usando imágenes de lunares o manchas mediante un algoritmo de redes neuronales artificiales?

1.4 Delimitación del Problema

Antes que nada, el pre-diagnóstico solo será para médicos. Ya que, uno de los principales propósitos del sistema es para el personal de salud que no tiene una especialidad en cáncer de piel.

Por otra parte, el sistema solo se encargará de hacer pre-diagnósticos, no será capaz de hacer un diagnóstico absoluto. No es un especialista en el tema, solo es un comparador y clasificador de imágenes.

También, el sistema no tendrá la dependencia del idioma, porque, solo se enfocará en regiones marginadas y poblaciones pequeñas de México.

En todo caso, el sistema de Pre-diagnóstico solo procesará melanomas, no aplicará en otro tipo de cáncer de piel como podría ser:

- Carcinomas de células de Merkel³,
- Linfoma cutáneo⁴
- Sarcoma de Kaposi⁵.

Asimismo, se limitará a solo pre-diagnosticar humanos, no será aplicable en animales.

³ Enfermedad por la que se forman células malignas (cancerosas) en la piel. Por lo general en la piel expuesta al sol como una sola masa indolora. [28].

⁴ Cáncer que comienza en las células del sistema linfático.

⁵ Enfermedad por la que se forman tumores malignos (cancerosos) en la piel, las membranas mucosas, los ganglios linfáticos y otros órganos.

1.5 Objetivos

1.5.1. Objetivo General

Desarrollar un sistema para un pre-diagnostico en melanomas benignos y malignos utilizando Redes neuronales artificiales

1.5.2 Objetivos Específicos

- Hacer uso de la base de datos ISIC para la obtención de imágenes y procesarlas para su uso.
- Diseñar un algoritmo de redes neuronales artificiales para la clasificación de melanomas benignos y malignos.
- Entrenar al sistema para reconocer los lunares benignos y malignos.
- Validar el sistema con nuevas imágenes para conocer su eficiencia.

1.7 Hipótesis

Si se usa un sistema basado en redes neuronales artificiales será posible identificar melanomas benignos y malignos y hacer un pre-diagnóstico de cáncer de piel en lunares.

Capítulo II . Marco Teórico

2.1 Matlab⁶

Se trata de un software matemático para cálculo científico basado en matrices. Ofrece un entorno de desarrollo integrado muy versátil con un lenguaje de programación propio⁷. Está disponible para los sistemas operativos Windows, Unix y Apple Mac OS X [4]. Ver la Figura 2.




Figura 2. Logo de Matlab.org

Es una poderosa herramienta de muy alto nivel de la corporación diseñado para cómputo matemático y científico que en un mismo ambiente es muy fácil de usar, integra cálculos, visualización y programación. Algunos de los usos más comunes del cómputo técnico son: [5].

- Δ Cálculo matemático.
- Δ Desarrollo de algoritmos.
- Δ Modelado y simulación.
- Δ Adquisición de datos.
- Δ Análisis de datos.
- Δ Obtención de gráficas.

⁶Es la abreviatura de **MA**TRIX **LAB**ORATORY (laboratorio de matrices). [5]

⁷Lenguaje M

- Δ Desarrollo de interfaces gráficas.
- Δ Programación grafica con simulink.
- Δ Interface con hojas de cálculo.

Matlab fue desarrollado en 1984 por Jack Little y Cleve Moler quienes crearon la compañía The MathWorks, Inc. en Natick, Massachusetts. [5]

2.2.1 Toolboxes

Con Matlab⁸ se ha desarrollado una colección de herramientas llamadas toolboxes, que programadas en lenguaje-m pueden realizar un conjunto de actividades en ciertas áreas de la ingeniería, las ciencias, las finanzas y la economía. Algunas de estas toolboxes son enfocadas a sistemas de control, procesado de señales, procesado de imágenes, lógica difusa, redes neuronales, simulación, optimización, finanzas y economía entre otras. [5]

Cuando salió a la luz la primera versión de MATLAB tenía cerca de *80 funciones* integradas para realizar operaciones matriciales. Hoy en día contiene *más de 11,000 funciones* algunas de ellas contenidas dentro de los toolboxes. [5]

Una parte importante en lo que respecta a toolboxes ha evolucionado hasta convertirse en lo que se conoce como *Simulink*, que permite realizar complicadas operaciones de control, procesado de imágenes, entre otras aplicaciones, mismas que se pueden realizar con programación gráfica. [5]

⁸ Para más información acerca de MATLAB puede visitar el siguiente enlace https://la.mathworks.com/matlabcentral/?s_tid=gn_mlc

2.2 Python

Lenguaje de programación de alto nivel, interpretado y multipropósito. En la actualidad es uno de los lenguajes de programación más empleados para el desarrollo del software. Puede ser utilizado en diversas plataformas y sistemas operativos entre los que podemos detectar los más populares, como Windows, Mac OS X y Linux, como también puede funcionar en Smartphones. [6]

Python presenta una serie de ventajas, tanto para el uso profesional como para el aprendizaje de la programación. Es un lenguaje muy expresivo, es decir, los programas son muy compactos: un programa suele ser bastante más corto que su equivalente en lenguajes como C. (Python llega a ser considerado por muchos un lenguaje de programación de muy alto nivel). Es muy legible. Ofrece un entorno interactivo que facilita la realización de pruebas y ayuda a despejar dudas de ciertas características de lenguaje. El entorno de Python detecta mucho de los errores que escapa al control de los compiladores y proporciona información para detectarlos y corregirlos. Puede usarse como lenguaje imperativo experimental o como lenguaje orientado a objetos. Posee un rico lenguaje de estructura de datos que se pueden manipular de modo sencillo. Estas características hacen que sea relativamente fácil traducir métodos de cálculos a programas Python. [7] Ver Figura 3



Figura 3. Logotipo de Python.org

2.3 Jupyter

El Proyecto Jupyter es un proyecto de código abierto sin fines de lucro, nacido del Proyecto IPython en 2014, ya que evolucionó para respaldar la ciencia de datos interactiva y la computación científica en todos los lenguajes de programación. Jupyter siempre será un software de código abierto al 100%, de uso gratuito para todos y lanzado bajo los términos liberales de la licencia BSD modificada. [8]

Todas las interacciones en línea y en persona y las comunicaciones directamente relacionadas con el proyecto están cubiertas por el Código de conducta de Jupyter. Este Código de conducta establece expectativas para permitir que una comunidad diversa de usuarios y contribuyentes participen en el proyecto con respeto y seguridad. [8]

El rol del Consejo Directivo de Jupyter es garantizar, a través del trabajo y el servicio a la comunidad más amplia de Jupyter, el bienestar a largo plazo del proyecto, tanto técnicamente como comunitario. El Consejo Directivo de Jupyter actualmente consta con 16 miembros. [8]

Project Jupyter existe para desarrollar software de código abierto, estándares abiertos y servicios para computación interactiva en docenas de lenguajes de programación. [9]

El cuaderno Jupyter es una aplicación web de código abierto que le permite crear y compartir documentos que contienen código en vivo, ecuaciones, visualizaciones y texto

narrativo. Los usos incluyen: limpieza y transformación de datos, simulación numérica, modelado estadístico, visualización de datos, aprendizaje automático y mucho más. [9]



Figura 4. Logo de Jupyter.org [9]

2.4 Sistema

Comprende una metodología para la construcción de modelos, que establece procedimientos y técnicas para el uso de lenguajes formalizado. [10]

2.5 Segmentación

Consiste en dividir la imagen en regiones con atributos similares, con el fin de poder aislar los distintos elementos que la componen y extraer aquellos que nos resulten de interés. [11]

2.6 Imagen

Se denomina imagen a la representación figurativa de una cosa. Es la representación de una realidad captada a través de los sentidos. Las imágenes son captadas por nuestra vista, y permanecen allí. Pueden ser plasmadas. [12]

Arreglo bidimensional de píxeles con diferente intensidad luminosa (escala de gris). Si la intensidad luminosa de cada píxel se representa por n bits, entonces existirán 2^n escalas de gris diferentes. [13]

Matemáticamente, una imagen se representa por $r = f(x, y)$, donde r es la intensidad del píxel cuyas coordenadas son (x, y) . Matemáticamente, un sistema para procesar imágenes se representa como $g(x, y) = T [f(x, y)]$. [13]

- **Color:** El color se forma mediante la combinación de los tres colores básicos rojo, azul y verde (en inglés RGB).
- **Brillo:** Indica si un área está más o menos iluminada.
- **Tono:** Indica si un área parece similar al rojo, amarillo, verde o azul o a una proporción de ellos.
- **Luminosidad:** Brillo de una zona respecto a otra zona blanca en la imagen.
- **Croma:** Indica la coloración de un área respecto al brillo de un blanco de referencia. [13]

Para obtener una imagen a color debe transformarse primero los parámetros cromáticos en eléctricos y representar los colores, lo cual puede realizarse de diferentes maneras, dando lugar a diferentes espacios de colores o mapas de color. [13]

2.7 Pixel

El píxel es la unidad mínima de visualización de una imagen digital. [14]. El píxel es el menor punto en una imagen. La combinación de muchos píxeles genera una imagen y

cuanto mayor la cantidad de píxeles, más definida es la imagen [15]. Su plural es píxeles o pixeles. También llamado pixel, pel, punto o dot. También se le dice píxel al elemento más pequeño controlable en una pantalla como un LCD. [16]. Ver la Figura 5.




Figura 5. Si aplicamos el zoom sobre ella observaremos que está formada por una parrilla de puntos o píxeles como se muestra en la ilustración. [16]

2.8 Resolución de Imagen

Es el grado de detalle o calidad de una imagen digital ya sea escaneada, fotografiada o impresa. Este valor se expresa en *ppp* (píxeles por pulgada) o en inglés *dpi* (dots per inch). Cuantos más píxeles contenga una imagen por pulgada lineal, mayor calidad tendrá.

[14]

2.9 Profundidad de Color

La profundidad de color se refiere al número de bits necesarios para codificar y guardar la información de color de cada píxel en una imagen. Un bit es una posición de memoria que puede tener el valor 0 ó 1. Cuanto mayor sea la profundidad de color en bits, la imagen dispondrá de una paleta de colores más amplia. Se utiliza 1-bit para imágenes en blanco/negro, sin grises (0=color negro, 1= color blanco), 2-bits = 4 colores (00=color

negro, 01=color X, 10=color Y, 11=color blanco), 3-bits = 8 colores, 8-bits = 256 colores, 24- bits = 16.7 millones de colores. [14].

2.10 Modelos de Color

Llamamos modo de color al sistema de coordenadas que nos permiten describir el color de cada píxel utilizando valores numéricos. Los modos de color más utilizados son [14]:

- a) **Modo monocromático.** Se corresponde con una profundidad de color de 1 bit. La imagen está formada por píxeles blancos o píxeles negros puros [14]. Como se muestra en la Figura 6.



Figura 6. Imagen modo monocromático. [14]

- b) **Modo Escala de Grises.** Maneja el canal negro y permite 256 tonos de gris entre el blanco y negro puros [14]. Como se muestra en la Figura 7.



Figura 7. Imagen modo Escala de Gises. [14]

- c) **Modo Color indexado.** Utiliza un canal de color indexado de 8 bits pudiendo obtener con ello hasta un máximo de 256 colores (28) [14]. Como se muestra en la Figura 8.



Figura 8. Imagen modo Color indexado. [14]

- d) **Modo RGB.** Cada color se forma por combinación de tres canales. Cada canal se corresponde con un color primario: Red (rojo), Green (verde), y Blue (azul). Asigna un valor de intensidad a cada color que oscila entre 0 y 255. De la combinación surgen hasta 16,7 millones de colores. Ejemplo: El valor R:255, G:0, B:0 representa al color rojo puro. [14]. Como se muestra en la Figura 9.



Figura 9. Imagen modo RGB. [14].

- **Espacio RGB** Se basa en la combinación de tres señales de luminancia cromática distinta: rojo, verde, azul (*Red, Green, Blue*). La forma más sencilla de obtener un color específico es determinar la cantidad de color rojo, verde y azul que se requiere combinar para obtener el color deseado, ver la figura 10; para lo cual se realiza la suma aritmética de las componentes: $X = R + G + B$, gráficamente representada por un cubo. [13]

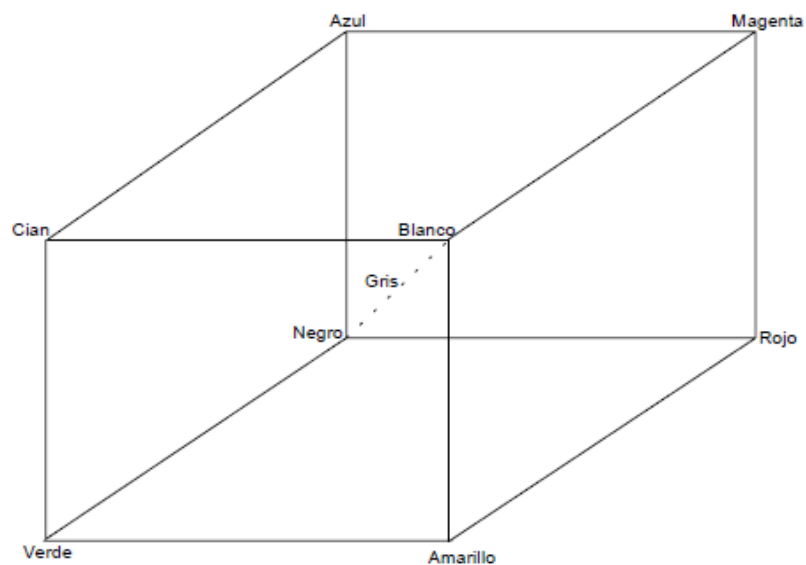


Figura 10. Espacio de Colores RGB [13]

- En la recta que une el origen con el valor máximo se encuentran ubicados los grises (escala de gris) debido a que sus tres componentes son iguales. Cuando una cámara adquiere una imagen a color, para cada píxel en color se tienen en

realidad 3 componentes, una para cada uno de los colores básicos (rojo, verde y azul); la ganancia máxima para cada componente corresponde a la longitud de onda de los tres colores básicos. [13]

- e) **HSV**. Cada color surge de los valores de estos tres parámetros: *Hue* (Tono) que es el valor del color: rojo, azul, verde, etc. En GIMP se expresa en grados y oscila entre 0 y 360. *Saturation* (Saturación) que se refiere a la pureza del color y va del 0% al 100%. *Brightness* (Brillo) referencia la intensidad de luz del color, es decir, la cantidad de negro o blanco que contiene estando su valor entre 0 (negro) y 100 (blanco). Ejemplo: El color rojo puro tiene un código RGB como (255,0,0) y también un código HSB (0,100,100). En la mayoría de programas de tratamiento de imágenes se puede elegir un color introduciendo su código RGB –es la opción más frecuente- o alternativamente su código HSB. En ambos casos la imagen maneja una paleta de colores de 24 bits [14]. Como se muestra en la Figura 11.



Figura 11. Paleta de colores HSV. [14]

- f) **Modo CMYK**. Cada color se forma por combinación de cuatro canales. Cada canal se corresponde con un color primario de impresión: Cyan (Ciano), Magenta (Magenta), Yellow (Amarillo) y Black (Negro). Cada canal puede tener como valor entre 0 y 255. Se trata de imágenes con una profundidad de color de 32 bits [14]. Como se muestra en la Figura 12.



Figura 12. Comparación de imágenes en modo RGB y CMYK. [14]

2.11 Formatos de imagen

Las imágenes digitales se pueden guardar en distintos formatos. Cada uno se corresponde con una extensión específica del archivo que lo contiene. Los más utilizados en la actualidad son: [14].

2.11.1 BMP (Bitmap = Mapa de bits). [14]

- Ha sido muy utilizado porque fue desarrollado para aplicaciones Windows.
- La imagen se forma mediante una parrilla de píxeles.
- El formato BMP no sufre pérdidas de calidad y por tanto resulta adecuado para guardar imágenes que se desean manipular posteriormente.
- Ventaja: Guarda gran cantidad de información de la imagen.
- Inconveniente: El archivo tiene un tamaño muy grande.

2.11.2 GIF (Graphics Interchange Format = Formato de Intercambio Gráfico). [14]

- Ha sido diseñado específicamente para comprimir imágenes digitales.
- Reduce la paleta de colores a 256 colores como máximo (profundidad de color de 8 bits).

- Admite gamas de menor número de colores y esto permite optimizar el tamaño del archivo que contiene la imagen.
- Ventaja: Es un formato idóneo para publicar dibujos en la web.
- Inconveniente: No es recomendable para fotografías de cierta calidad ni originales ya que el color real o verdadero utiliza una paleta de más de 256 colores.

2.11.3 JPG-JPEG (Joint Photographic Experts Group = Grupo de Expertos Fotográficos Unidos). [14]

- A diferencia del formato GIF, admite una paleta de hasta 16 millones de colores.
- Es el formato más común junto con el GIF para publicar imágenes en la web.
- La compresión JPEG puede suponer cierta pérdida de calidad en la imagen. En la mayoría de los casos esta pérdida se puede asumir porque permite reducir el tamaño del archivo y su visualización es aceptable. Es recomendable utilizar una calidad del 60-90 % del original.
- Cada vez que se modifica y guarda un archivo JPEG, se puede perder algo de su calidad si se define cierto factor de compresión.
- Las cámaras digitales suelen almacenar directamente las imágenes en formato JPEG con máxima calidad y sin compresión.
- Ventaja: Es ideal para publicar fotografías en la web siempre y cuando se configuren adecuadamente dimensiones y compresión.
- Inconveniente: Si se define un factor de compresión se pierde calidad. Por este motivo no es recomendable para archivar originales.

2.11.4 TIF-TIFF (Tagged Image File Format = Formato de Archivo de Imagen Etiquetada). Almacena imágenes de una calidad excelente. **[14]**.

- Utiliza cualquier profundidad de color de 1 a 32 bits.
- Es el formato ideal para editar o imprimir una imagen.
- Ventaja: Es ideal para archivar archivos originales.
- Inconveniente: Produce archivos muy grandes.

2.11.5 PNG (Portable Network Graphic = Gráfico portable para la red). **[14]**

- Es un formato de reciente difusión alternativo al GIF.
- Tiene una tasa de compresión superior al formato GIF (+10%).
- Admite la posibilidad de emplear un número de colores superior a los 256 que impone el GIF.
- Debido a su reciente aparición sólo es soportado en navegadores modernos como IE 4 o superior.

2.12 Procesamiento de Imágenes

Después de adquirir la imagen, en un procesamiento no siempre se siguen todos los pasos. Las partes fundamentales del procesamiento digital de imágenes son las siguientes.
[17]

- 1. Adquisición de imágenes:** Generalmente incluye preprocesamiento (p. Ej. Escalar la imagen).
- 2. Mejora de la imagen.** La idea de este paso es obtener detalles que no se veían, o simplemente subrayar ciertas características de interés. Que se “vea mejor”.

3. **Restauración de la imagen.** También mejora la apariencia de la imagen, a diferencia de la mejora de la imagen, subjetiva, la restauración es objetiva, en el sentido en que las técnicas de restauración tienden a ser modelos probabilísticos o matemáticos de degradación de la imagen (¿Cómo era esta imagen antes de ser dañada?)
4. **Procesamiento del color.** Procesamientos especiales para el color.
5. **Ondeletas.** Fundamentalmente utilizadas para representar imágenes en varios grados de resolución. Se utiliza principalmente en compresión.
6. **Compresión.** Reduce el almacenamiento requerido para guardar una imagen, o el ancho de banda para transmitirla.
7. **Procesamiento morfológico.** Herramientas para extraer componentes de la imagen útiles para la representación y descripción de formas.
8. **Segmentación.** Divide una imagen en sus partes constituyentes.
9. **Representación y descripción.** Se toman decisiones tales como si la forma obtenida debe ser tratada como una frontera o una región, y extrae atributos que resultan en información cuantitativa de interés.

2.13 Redes Neuronales Artificiales

Son modelos que intentan reproducir el comportamiento del cerebro. [18]. La neurona artificial es una unidad procesadora con cuatro elementos funcionales [19]:

2.13.1 El elemento receptor

A donde llegan una o varias señales de entrada x_i que generalmente provienen de otras neuronas y que son atenuadas o amplificadas cada una de ellas con arreglo a un factor de peso w_i que constituye la conectividad entre la neurona fuente de donde provienen y la neurona de destino en cuestión

2.13.2 El elemento sumador

Que efectúa la suma algebraica ponderada de las señales de entrada, ponderándolas de acuerdo con su peso, aplicando la siguiente expresión: [19]

$$S = \sum w_i x_i \quad (1)$$

2.13.3 El elemento de función activadora

Que aplica una función no lineal de umbral (que frecuentemente es una función escalón o una curva logística) a la salida del sumador para decidir si la neurona se activa, disparando una salida o no. [19].

2.13.4 El elemento de salida

Que es el que produce la señal, de acuerdo con el elemento anterior, que constituye la salida de la neurona. [19]. Como se muestra en la Figura 13.




Figura 13. Esquema de neurona artificial. [19]

2.14 Ventajas que ofrecen las redes neuronales

2.14.1 Aprendizaje adaptativo

Aprenden a llevar a cabo ciertas tareas mediante un entrenamiento con ejemplos ilustrativos. Como las redes neuronales pueden aprender a diferenciar patrones mediante ejemplos y entrenamientos, no es necesario elaborar modelos a priori ni necesidad de especificar funciones de distribución de probabilidad. Son dinámicos, pues son capaces de estar constantemente cambiando para adaptarse a las nuevas condiciones. Una red neuronal no necesita un algoritmo para resolver un problema, ya que ella puede generar su propia distribución de pesos en los enlaces mediante el aprendizaje. [20]

2.14.2 Auto-organización

Las redes neuronales emplean su capacidad de aprendizaje adaptativo para auto-organizar la información que reciben durante el aprendizaje y/o la operación; consiste en la modificación de la red neuronal completa para llevar a cabo un objetivo específico. Cuando

las redes neuronales se usan para reconocer ciertas clases de patrones, ellas auto-organizan la información usada [20].

2.14.3 Tolerancia a fallos

La razón por la que las redes neuronales son tolerantes a los fallos es que tienen su información distribuida en las conexiones entre neuronas, existiendo cierto grado de redundancia en este tipo de almacenamiento. Las redes neuronales almacenan información no localizada. Por lo tanto, la mayoría de las interconexiones entre los nodos de la red tendrán sus valores en función de los estímulos recibidos, y se generará un patrón de salida que represente la información almacenada. Hay dos aspectos distintos respecto a la tolerancia a fallos [20]:

- Las redes pueden aprender a reconocer patrones con ruido, distorsionados o incompletos. Esta es una tolerancia a fallos respecto a los datos.
- Las redes pueden seguir realizando su función (con cierta degradación) aunque se destruya parte de la red

2.14.4 Operación en tiempo real

Casi en la totalidad de las áreas de aplicación, es la necesidad de realizar procesos con datos de forma muy rápida. Las redes neuronales se adaptan bien a esto debido a su implementación paralela. [20].

2.15 Perceptrón

El perceptrón fue la primera red neuronal. El perceptrón utiliza elementos altamente no lineales. El elemento básico de cómputo en el perceptrón es un dispositivo conocido como la unidad de lógica umbral (ULU o en inglés TLU (*threshold logic unit*)) [21].⁹ Como se muestra en la Figura 14.

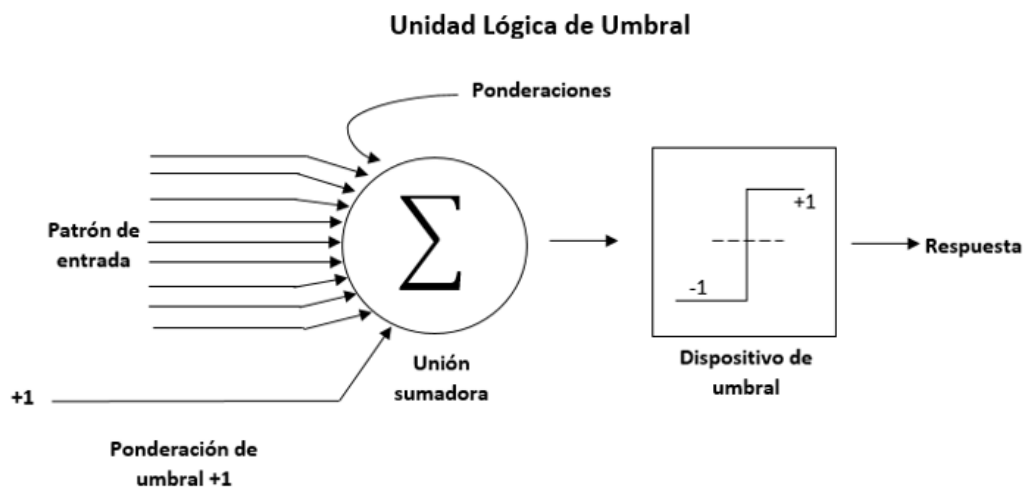


Figura 14. Una unidad de lógica de umbral [21]

2.15.1 Arquitectura del Perceptrón

El perceptrón empezaba con una superficie sensorial, conocida como retina, que se conecta en una segunda capa, la capa de asociación (capa A). Las conexiones del modelo de la retina a la capa A podía ser aleatoria, o tener una conectividad local. Cada unidad en la capa A, únicamente percibía un subconjunto de las células de la retina. La ruta desde la retina hasta la capa A, no estaba totalmente conectada, en la que cada unidad de la capa A percibiría a cada unidad retinal, sino parcialmente conectada, en la que una unidad de capa

⁹ Es la forma de la neurona genérica conectivista. Forma la suma de las actividades de los patrones de entrada por las ponderaciones, esto es el producto interno entre los patrones de entrada y las fuerzas de conexión.

A percibiría solamente parte de la retina. Por lo tanto, cada unidad de la capa A estaba calculando una función diferente de la imagen en la retina del modelo [21]. Como se muestra en la Figura 15.

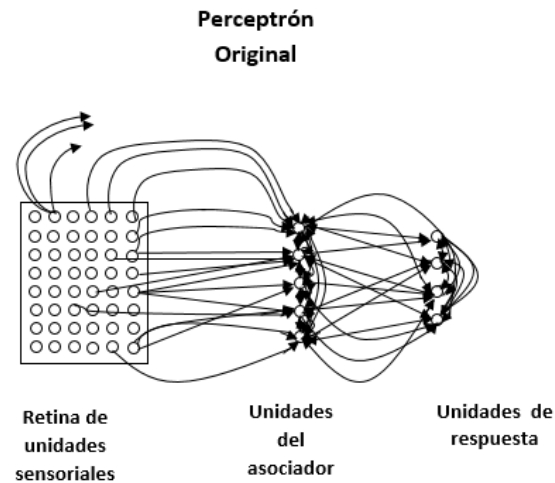


Figura 15. Arquitectura Original del Perceptrón [21]

2.15.2 Aprendizaje del perceptrón

Las conexiones de la capa A a la capa R son modificables; aquellas de la retina a la capa A están fijas. Nuevamente, basándose sobre la representación de la capa de salida, tan solo se examina las conexiones de una unidad de la capa R hasta que haga la clasificación [21].

Supongamos que ahora dos clases de patrones linealmente separables, que llamaremos $\{a\}$ y $\{b\}$. Supongamos que tenemos cierto número de ejemplos de cada clase: Presentamos los ejemplos al perceptrón en cierta clase de secuencia, a la que se hace referencia como *secuencia de entrenamiento*, $\{y\}$. El K -enésimo miembro de la secuencia

de entrenamiento se conoce como $\{Y_k\}$. El supervisor conoce la clasificación correcta para cada patrón puede ajustar todos los pesos. [21].

2.16 Red Neuronal Convolutiva

Una red neuronal convolutiva es un tipo de red multicapa que consta de diversas capas convolucionales y de *pooling* (submuestreo) alternadas, y al final tiene una serie de capas *full-connected* como una red perceptrón multicapa. La entrada de una red capa convolutiva suele ser, generalmente, una imagen $m * m * r$, donde m es tanto la altura como el ancho de la imagen y r es el número de canales. Las capas convolucionales tienen k filtros (o *kernels*) cuyas dimensiones son $n * n * q$, donde n y q son elegidas por el diseñador. Cada filtro genera mediante convolución un mapa de rasgos o características de tamaño $(m - n + 1) * (m - n + 1) * p$, siendo p el número de filtros que se desean usar. Después cada mapa es sub-muestreado en la capa de pooling con la operación “*mean pooling*” o “*max pooling*” sobre regiones contiguas de tamaño $p * p$ donde p puede tomar valores desde 2 para imágenes pequeñas hasta, comúnmente, no más de 5 para imágenes grandes. Antes o después del submuestreo, se aplica una función de activación sigmoidea más un sesgo para cada mapa de rasgos. Ver Figura 16. [22]




Figura 16. Esquema básico de una Red Neuronal Convolutiva. [22]

2.16.1 Capa Convolutiva

Los parámetros de la capa convolutiva consisten en un conjunto de filtros aprendibles. Cada filtro es pequeño espacialmente (en alto y ancho), pero se extienden a través de la profundidad total del volumen de entrada. Por ejemplo, un filtro típico en la primera capa de una red neuronal convolutiva podría ser de tamaño $m \times m \times 3$ (m píxeles de ancho y alto, 3 por 3 canales de color). Cada filtro se desliza (más preciso, se convoluciona) a través del alto y ancho de la entrada y se calcula el producto punto entre las entradas del filtro y la imagen de entrada en cualquier posición. Mientras desliza el filtro por el alto y ancho del volumen de entrada se produce un mapa de activación bidimensional que obtiene las respuestas del filtro en cada posición espacial. Intuitivamente, la red aprenderá los filtros que se activan cuando ven algún tipo de característica visual como el borde de alguna orientación o una mancha de algún color en la primera capa o eventualmente patrones completos como un panal de abeja o algo parecido a una llanta en capas más altas de la red. Si tenemos un conjunto de filtros en cada capa convolutiva (*Conv layer*) por ejemplo, 12 filtros, cada uno de estos producirá un mapa de activación bidimensional. Estos mapas de activación se apilan a lo largo de la dimensión de profundidad y producirá un volumen de salida. [23]

2.16.2 Capa Pooling

Es común agregar periódicamente una capa *Pooling* entre capas convolutivas sucesivas. Su función es reducir progresivamente el tamaño espacial de la representación para reducir la cantidad de parámetros y cálculos en la red y por lo tanto controlar el *overfitting* (sobre aprendizaje del conjunto de entrenamiento, con baja precisión al predecir

resultados de nuevos datos) y así lograr la invarianza espacial para distorsiones de entrada y traslación (lograr reconocer ciertas características de la imagen, sin importar en qué lugar de la imagen se encuentren). La capa *Pooling* opera de manera independiente en cada arreglo bidimensional a lo largo de la profundidad total de la entrada y cambia su tamaño espacialmente, usando normalmente la operación MAX. La forma más común es una capa *Pooling* con filtros de tamaño 2×2 aplicado con un *stride* de 2, que reduce cada arreglo bidimensional de la profundidad total de la entrada por 2, descartando 75% de las activaciones. Cada operación MAX en este caso tomaría el máximo de 4 números (región de 2×2). La profundidad permanece sin cambio alguno. Resumiendo, la capa *pooling*: [23]

1. Acepta un volumen de tamaño $W_1 \times H_1 \times D_1$
2. Requiere de dos hiperparámetros:
 - La extensión espacial F ,
 - El *stride* S ,
3. Produce un volumen de tamaño $W_2 \times H_2 \times D_2$ donde:
 - $W_2 = \frac{W_1 - F}{S + 1}$
 - $H_2 = \frac{H_1 - F}{S + 1}$
 - $D_2 = D_1$
4. No introduce parámetros, puesto que calcula una función fija de la entrada.
5. No es común *usar zero-padding* para capas *pooling*.




Figura 17. Proceso de la capa pooling. [23]

Ver Figura 17. La capa *pooling* reduce el volumen espacialmente, independientemente de la profundidad del volumen de entrada. Izquierda: en este ejemplo, al volumen de entrada $[224 \times 224 \times 64]$ se le aplica el *pooling* con un filtro de tamaño 2, *stride* 2 y resulta en un volumen de salida de $[112 \times 112 \times 64]$. La profundidad del volumen se conserva. Derecha: La operación más común de reducción es MAX, aquí se muestra con un *stride* de 2 y un filtro de 2×2 . Se toma el número más grande entre 4 posibles (por el filtro de 2×2) [23]

2.17 Red Neuronal Backpropagation

El funcionamiento de la red *backpropagation* (BPN) consiste en el aprendizaje de un conjunto predefinido de pares de entradas-salidas dados como ejemplo: primero se aplica un patrón de entrada como estímulo para la primera capa de las neuronas de la red, se va propagando a través de todas las capas superiores hasta generar una salida, se compara el resultado en las neuronas de salida con la salida que se desea obtener y se calcula un valor de error para cada neurona de salida. A continuación, estos errores se transmiten hacia atrás, partiendo de la capa de salida hacia todas las neuronas de la capa intermedia que

contribuyan directamente a la salida. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido un error que describa su aportación relativa al error total. Basándose en el valor del error recibido, se reajustan los pesos de conexión de cada neurona, de manera que en la siguiente vez que se presente el mismo patrón, la salida esté más cercana a la deseada [18].

La importancia de la red *backpropagation* consiste en su capacidad de auto-adaptar los pesos de las neuronas de las capas intermedias para aprender la relación que existe entre un conjunto de patrones de entrada y sus salidas correspondientes. Es importante la capacidad de generalización, facilidad de dar salidas satisfactorias a entradas que el sistema no ha visto nunca en su fase de entrenamiento. La red debe encontrar una representación interna que le permita generar las salidas deseadas cuando se le dan entradas de entrenamiento, y que pueda aplicar, además, a entradas no presentadas durante la etapa de aprendizaje para clasificarlas. [18].

2.17.1 Aprendizaje de Backpropagation

La aplicación del algoritmo tiene dos fases, una hacia delante y otra hacia atrás. Durante la primera fase el patrón de entrada es presentado a la red y propagado a través de las capas hasta llegar a la capa de salida. Obtenidos los valores de salida de la red, se inicia la segunda fase, comparándose estos valores con la salida esperada para así obtener el error. Se ajustan los pesos de la última capa proporcionalmente al error. Se pasa a la capa anterior con una retro-propagación del error, ajustando los pesos y continuando con este proceso hasta llegar a la primera capa. De esta manera se han modificado los pesos de las

conexiones de la red para cada patrón de aprendizaje del problema, del que conocíamos su valor de entrada y la salida deseada que debería generar la red ante dicho patrón. [18]

2.18 Irradiancia Solar

Es la magnitud empleada para indicar el valor de la radiación incidente en una superficie. En el caso del Sol, se define como la energía solar recibida por cada m^2 en un segundo. La irradiancia solar en la cima de la atmósfera, en dirección perpendicular a los rayos solares, tiene un valor medio de 1.367 W/m^2 . Este valor se denomina constante solar porque se mantiene prácticamente constante durante decenas o centenares de años, ya que, al ser básicamente dependiente de factores astronómicos o astrofísicos, su variación es muy lenta. [3].

La radiación solar se atenúa debido a procesos de absorción y difusión que producen los gases y partículas de la atmósfera y las nubes. La irradiancia solar incidente en el suelo no suele superar los 1.000 W/m^2 , dependiendo mucho del lugar, la hora del día, época del año y estado del cielo. [3].

2.18.1 Radiación solar directa y difusa

Una parte de la irradiancia solar que incide en el suelo proviene directamente del disco solar (irradiancia solar directa) y otra proviene del cielo y las nubes (irradiancia solar difusa). [3] Ver la figura 18 y 19.




Figura 18. Difusión de la luz solar directa. [3]




Figura 19. Radiación solar difusa. [3]

Para cielos despejados, la irradiancia directa predomina en las horas centrales del día, y varía con el coseno del ángulo cenital del sol (ley de coseno). Cuando el sol está oculto por las nubes o en los crepúsculos, casi toda la irradiancia es difusa. [3].

2.18.2 Tipos de Radiación.

El sol emite un amplio espectro de radiaciones, desde rayos gamma hasta longitudes de onda largas, de tipo infrarrojo. [3]. Ver tabla 3 y 4.

Tabla 3. Tipos de radiaciones según su longitud de onda. [3]

Clase de Radiación	Longitud de Onda
Rayos gama	< 0,1 nm
Rayos X	0,1 – 100 nm
Ultravioleta C (UVC)	100 - 280 nm
Ultravioleta B (UVB)	280 - 320 nm
Ultravioleta A (UVA)	320 - 400 nm
Visible	400 - 700 nm
Infrarroja A (IRA)	700 - 1,4 μm
Infrarroja B (IRB)	1,4 – 3,0 μm
Infrarroja C (IRC)	3,0 μm – 1 mm

Tabla 4. Tipos de radiaciones infrarrojas según su longitud de onda. [3]

Clase de Radiación	Longitud de Onda
Infrarrojo Cercano (NIR/IRA)	700 nm-1,4 μm
Infrarrojo de Onda Corta	1 – 3 μm
Infrarrojo Medio	3 – 5 μm
Infrarrojo de Onda Larga	5 – 14 μm
Infrarrojo Térmico	8 – 15 μm
Infrarrojo de Onda muy Larga	12 – 30 μm
Infrarrojo de Lejano	15 μm – 1 mm

La curva espectral se parece a la de un cuerpo negro (teórico) a una temperatura de 6.000°C. Las radiaciones solares más cortas se atenúan completamente en la alta atmósfera, de manera que a nivel de la superficie terrestre solamente llega una parte de ultravioleta B (UVB), ultravioleta A (UVA), visible (VIS) e infrarrojo cercano (NIR). [3].

Todos los cuerpos están constantemente emitiendo y recibiendo calor. Cuanto más calientes están, tanto mayor es su emisión. Los cuerpos a alta temperatura emiten su máxima radiación a una longitud de onda más corta que los de temperatura menor (ley de Wien). Por ejemplo, la radiación solar tiene su máximo en 474 nm (recuerde que 1 nm equivale a 0,001 μm) y corresponde a una temperatura de la fotosfera solar del orden de los 6.000°C. En cambio, la superficie de la Tierra, a una temperatura del orden de 25°C emite su máximo de radiación a 10 μm . La nomenclatura de los diversos intervalos depende mucho del campo de aplicación y a veces se los intervalos se solapan. [3].

2.19 Dermatólogo

La dermatología es la rama de la medicina que se dedica al estudio de la piel y las enfermedades que la afectan [24]. Se ocupa de los cuidados de la piel, las mucosas, las uñas, el pelo y el cabello. [25] Trata del conocimiento de las lesiones elementales que pueden instalarse sobre la superficie cutánea¹⁰, sus anexos y las mucosas accesibles. [26].

2.20 Tipos de Piel

El color de la piel está determinado por la cantidad y tipo del pigmento, la “melanina”, pigmento producido exclusivamente por unas células especializadas llamadas melanocitos. [27].

Existen dos tipos de melanina, la feomelanina (de rojo a amarillo) y la eumelanina (de marrón oscuro a negro). De cuatro a seis genes, que operan bajo dominancia incompleta, determinan el tipo de melanina y las cantidades en cada sujeto. [27].

El hecho de que la piel se broncee como consecuencia de la exposición a los rayos solares constituye una reacción defensiva de la piel y evita que se quemee y se dañen los núcleos celulares. [27].

¹⁰ El término cutáneo estamos empleando un adjetivo que se utiliza para referirse a todo aquello que es perteneciente o relativo al cutis [12]

La clasificación de tipo de piel, conocida como fototipo, depende de la cantidad de melanina en la piel. Se evalúa en una escala de 1 a 6. Como se muestra en la Figura 20. [27].




Figura 20. Fototipo. [25]

2.20.1 Fototipo

Es un sistema de clasificación basado en la sensibilidad de una persona a la luz solar. Las personas con piel de tipo I y II están expuestas a un mayor riesgo de presentar lesiones de fotoenvejecimiento, incluyendo las arrugas y cáncer de piel. [27].

- **Tipo I.** Son personas con piel blanca, pelirrojos, con ojos azules y muchas pecas. Presentan fácilmente quemaduras importantes después de exponerse al sol. No se broncean nunca.
- **Tipo II.** Son rubios, con ojos azules o verdes. Se queman con facilidad y en alguna ocasión llegan a broncearse.
- **Tipo III.** Corresponde a la raza caucásica. Tienen ojos grises, pelo castaño, raramente se queman y llegan a broncearse, si consiguen no quemarse.
- **Tipo IV.** Son morenos de piel y con ojos marrones o negros. Sufren quemaduras mínimas y se broncean muy fácilmente.
- **Tipo V.** Tienen piel y ojos muy oscuros. Habitualmente no se queman y se broncean rápidamente y de color muy intenso.
- **Tipo VI.** Correspondería a la raza negra. En alguna ocasión también pueden quemarse.

2.21 Oncólogo

Médico que tiene una formación especial para diagnosticar y tratar el cáncer mediante quimioterapia, terapia¹¹ con hormonas, terapia biológica y terapia dirigida. [28]

Es un especialista en enfermedades tumorales y aunque atiende padecimientos benignos (quistes u otras bolitas en los senos), su campo de acción más fuerte lo constituyen los tumores malignos (CÁNCER). [29].

¹¹ Tratamiento de una enfermedad o alteración física o mental mediante diversas sustancias o métodosFuente especificada no válida.

2.22 Cáncer

Cáncer es el nombre que se da a un conjunto de enfermedades relacionadas. [28]. Se caracterizan por el desarrollo de células anormales, que se dividen, crecen y se diseminan sin control en cualquier parte del cuerpo. [30]

Es un proceso de crecimiento y diseminación¹² incontrolados de células. Puede aparecer prácticamente en cualquier lugar del cuerpo. El tumor suele invadir el tejido circundante y puede provocar metástasis¹³ en puntos distantes del organismo. [31].

2.23 Tumor

Es una masa anormal de tejido corporal. Los tumores pueden ser cancerosos (malignos) o no cancerosos (benignos). Ocurren cuando las células se dividen y se multiplican excesivamente en el cuerpo. Normalmente, el cuerpo controla la división y el crecimiento de las células. Se crean nuevas células para reemplazar a las viejas o para desempeñar nuevas funciones. Las células que están dañadas o que ya no se necesitan mueren para dar paso a las células de reemplazo sanas. [28].

2.24 Melanoma

El melanoma es el tipo más serio de cáncer de piel. Con frecuencia el primer signo de un melanoma es un cambio de tamaño, forma, color o textura de un lunar. La mayoría de

¹² Extracción mediante hidrólisis del radical NH₂ de un compuesto químico, principalmente de un aminoácido [33]

¹³ Las metástasis son tumores malignos desarrollados en otras partes del cuerpo a partir de células cancerígenas desplazadas del tumor primario de origen. [33]

los melanomas tienen un área negra o negra azulada. El melanoma también puede aparecer como un lunar nuevo. Puede ser negro, anormal o "de aspecto desagradable." [32]

2.24.1 Señales de alarma de melanomas

1. *Asimetría*: el contorno de una mitad no es igual al otro
2. *Bordes*: los bordes son desiguales, borrosos o irregulares
3. *Color*: el color es disparejo y puede incluir tonalidades negras, cafés y canela
4. *Diámetro*: hay cambios en el tamaño, generalmente se vuelven más grandes.
5. *Evolución*: cualquier cambio en el lunar en las últimas semanas o meses. [32]. Ver la Figura 21.




Figura 21. Señales de alarma de melanoma. [25]

El melanoma es una enfermedad por la que se forman células malignas (cancerosas) en los melanocitos¹⁴ cualquier lugar de la piel. Los lunares inusuales, (células que dan color a la piel). Hay diferentes tipos de cáncer que empiezan en la piel. El melanoma se puede presentar en la exposición a la luz solar y los antecedentes de salud pueden afectar el riesgo

¹⁴ Célula de la epidermis que se encarga de producir melanina, un pigmento pardo-oscuro de la piel, el pelo y los ojos

de melanoma. Los signos de melanoma son un cambio en el aspecto de un lunar o área pigmentada. [28]. Ver la Figura 22.




Figura 22. Anatomía de la piel que muestra la epidermis y la dermis. Los melanocitos están en la capa de células basales, en la parte más profunda de la epidermis. [28]

2.25 Carcinoma

Grupo de células anormales que permanecen en el mismo lugar en el que se formaron. No se diseminaron. Estas células anormales se pueden volver cancerosas y diseminarse hasta los tejidos vecinos sanos. También se llama enfermedad en estadio 0. [28]

Cáncer epitelial¹⁵ con tendencia a afectar los tejidos circundantes y que puede llegar a provocar metástasis distantes. El tumor suele ser compacto, nodular e irregular, con borde bien definido. Surge principalmente en la piel, los pulmones, el colon, el estómago, la próstata, el cuello uterino o las mamas. [33]

¹⁵ Tejido formado por una o más capas de células que están unidas entre sí y que recubren la superficie de distintos órganos y partes del cuerpo [33]

2.26 Cáncer de Piel (Cáncer Cutáneo)

El cáncer de piel comienza en la epidermis (capa externa), que se compone de células escamosas, células basales y melanocitos.

Hay diferentes tipos de cáncer de piel. Los cánceres de células escamosas y de células basales de la piel a veces se llaman cánceres de piel no melanomatosos. [28]. Ver la




Figura 23.

Figura 23. Anatomía de la Piel. Muestra la epidermis, la dermis y el tejido subcutáneo. [28]

El cáncer se puede originar en cualquier parte del cuerpo. Comienza cuando las células crecen descontroladamente sobrepasando a las células normales, lo cual dificulta que el cuerpo funcione de la manera que debería. [28]

2.27 Lunares

Los lunares son crecimientos sobre la piel. Se producen cuando las células productoras de pigmento¹⁶ de la piel, llamadas melanocitos, crecen en grupos. Los lunares son muy comunes. La mayoría de las personas tiene entre 10 y 40 lunares. Una persona puede desarrollar nuevos lunares hasta los 40 años aproximadamente. Suelen ir desapareciendo a medida que envejecemos.

Los lunares suelen ser rosados, morenos o marrones. Pueden ser planos o elevados. Generalmente son redondos u ovalados y no mayores que una goma de lápiz. [26].

¹⁶ En el cuerpo humano un pigmento es cualquier sustancia colorante de tipo orgánico. [33]

Capítulo III Metodología

3.1 Recopilación de imágenes y metadatos de melanomas malignos y benignos

Se realizó la obtención de imágenes de melanomas, tanto malignos como benignos, que este certificado por alguna fuente confiable. En internet el sitio web Archivo ISIC, es una página o banco web de Imágenes de melanomas, en donde, doctores especializados en dermatología suben fotografías para compartir información sobre el tema. Ver la Figura 24.

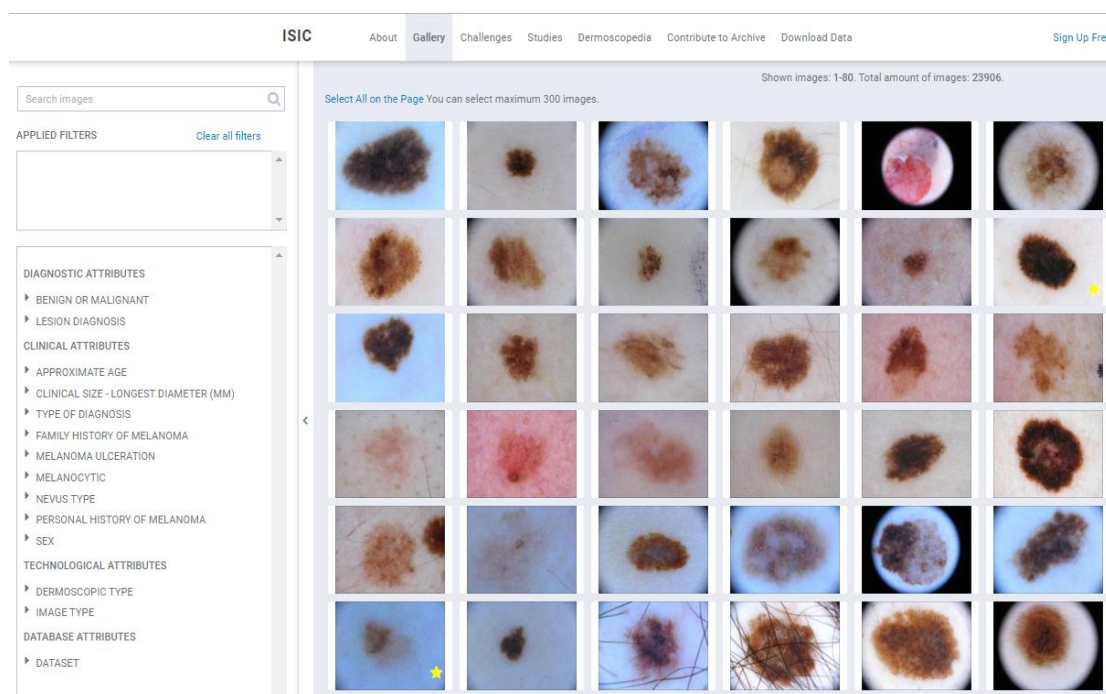


Figura 24. Banco de Imágenes de melanomas de Archivo ISIC. (<https://isic-archive.com>).

La página <https://isic-archive.com/#images> (Archivo ISIC), está certificada por el *Memorial Sloan Kettering Center of Cancer* ("MSKCC"), haciendo constar la legitimidad del sitio web. Ver la Figura 25.



Figura 25. Página de Inicio de Archivo ISIC (<https://www.isic-archive.com/#!/topWithHeader/onlyHeaderTop/gallery>).

El sitio web, cuenta con una base de 23,906 imágenes en donde despliega sus metadatos de cada melanoma mostrando su estado de clínico, cabe mencionar, que la información está destinada al público en general y solo es para uso informativo. Ver la Figura 26.

ISIC_0000000	
CLINICAL INFORMATION	
age_approx	55
anatom_site_general	anterior torso
benign_malignant	benign
diagnosis	nevus
diagnosis_confirm_type	
melanocytic	true
sex	female
ACQUISITION METADATA	
Dimensions (pixels)	1022 X 767
UNSTRUCTURED METADATA	
diagnosis	dysplastic nevus
id1	1
localization	Abdomen
site	bar

Figura 26. Base de Datos de cada melanoma (<https://isic-archive.com/#images>).

De la página Archivo ISIC, se descargaron el banco de imágenes orientado a 2 grupos, positivos (malignos) y negativos (benignos). Ver la Figura 27.

Nombre	Fecha de modifica...	Tipo	Tamaño
MSK-2 BENIGNOS	03/05/2018 22:23	WinRAR archive	97.531 KB
MSK-2 MALIGNOS	03/05/2018 23:35	WinRAR archive	985.521 KB

Figura 27. Descarga de las imágenes de melanomas en dos archivos .rar (malignos y benignos).

3.2 Red Neuronal tipo Perceptrón con metadatos

En un principio, se recabaron 240 datos de la página web Archivo ISIC. Se clasificaron de manera correcta en 2 grupos; el primer grupo destinado para enseñar al algoritmo a clasificar está conformado por 100 datos de melanomas malignos y 100 datos de melanomas benignos y el segundo grupo destinado para las pruebas de clasificación se encuentran 20 datos de melanomas malignos y 20 datos de melanomas benignos.

3.2.1 Método de la clasificación de los atributos encontrados en la base de datos de la página web *Archivo ISIC*

Se tomaron en cuenta de los 7 atributos solo se tomaron 2 el Tipo de melanoma y el tamaño. Ver tabla 5.

Tabla 5. Clasificación en los atributos de los metadatos sacados de la página web ISIC.

Melanoma	Benigno	1	Maligno	-1								
Edad	S/E											
Sexo	Femenino	1	Masculino	0								
Herencia	FALSO	1	VERDADERO	0								
Ubicación	Torso O	0	Torso A	1	Cuello	2	Brazo	3	Pierna	4	Palma/planta	5
Tipo	Nevus	0	lesión solar	1	lentigo simplex	2	melanoma	3	lentigo NOS	4		
Tamaño	S/E											

Para la clarificación de la tabla se tomaron en cuenta 7 atributos de los metadatos.

Cada atributo necesitaba un número de referencia para clasificar en los metadatos.

- **Melanoma:** en el caso del melanoma solo existen dos variantes, es positivo o negativo; para distinguirlos al **positivo** se le asignó el número **1** y al **negativo** el **-1**.
- **Edad y Tamaño:** en la *Edad* del paciente y en el *Tamaño* del melanoma no es necesario denominarlo con algún dígito ya que es un dato que no debe ser alterado ya que son factures importantes en el desarrollo del melanoma. *(Se le agrega el S/E para destacar que es Sin Especificación)*.
- **Sexo:** para el sexo es similar a la edad solo cuentan con 2 variantes, sea Masculino o Femenino; de esta manera, al **Masculino** se le asignó **0** y **Femenino 1**.
- **Herencia:** se demuestra la probabilidad ser vulnerable a tener melanomas por herencia de familia (padre, madre, abuelos), agregando en la tabla como **Falso (1)** en caso de tener un melanoma y no ser heredado, de lo contrario, es **Verdadero (0)** por ser heredado
- **Ubicación:** en los metadatos de ISIC, se obtiene los lugares en donde es habitual que hayan melanomas, en este caso, se dividen en 6 partes del cuerpo: **Torso O** (torso bajo) **0**, **Torso A** (alto) **1**, **cuello 2**, **brazo 3**, **pierna 4** y **palma** (de los pies y manos).
- **Tipo:** En este atributo se da a conocer si los melanomas son proporcionados por afectaciones solares, nacimiento o alguna enfermedad cutánea como se encuentran; los **nevus (0)** hace referencia a los melanomas benignos, lesión solar (1) quemaduras de sol, lentigo simplex (2), Melanoma (3) hacer referencia al melanoma maligno y lentigo NOS (4).

Ya con los dos atributos y estando clasificados se realiza una normalización. La normalización hace que los valores se encuentren entre cero a uno, de esta manera la matriz tendrá un mejor comportamiento en el sistema. Ver la Formula (2).

$$x^1 = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

3.2.2 Entrenamiento del Perceptrón con Metadatos

Obteniendo la matriz, se agrega a una variable en este caso es “p”; la matriz solo se tomó 42 melanomas de los 240. Se dividen en 21 son malignos y 21 benignos, en ese orden. Los primeros 42 datos se atribuye a el tamaño del lunar; los otros 42 datos son el tipo de lesión. Ver Tabla 6.

Tabla 6. Metadatos normalizados ordenadas en 2 filas separadas por ";". La primera fila es tamaño y segunda fila es tipo.

%No.	1	2	3	4	5	6	7	8	9	10
%Tamaño	0.07	0.09	0.20	0.34	0.23	0.18	0.11	0.16	0.34	0.20
%Tipo	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75
%No.	11	12	13	14	15	16	17	18	19	20
%Tamaño	0.66	0.30	0.18	0.32	0.16	0.20	0.89	0.23	0.05	0.18
%Tipo	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75
%No.	21	22	23	24	25	26	27	28	29	30
%Tamaño	0.34	0.07	0.05	0.09	0.05	0.20	0.05	0.18	0.36	0.08
%Tipo	0.75	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.25	0.00
%No.	31	32	33	34	35	36	37	38	39	40
%Tamaño	0.09	0.11	0.14	0.23	0.25	0.09	0.20	0.08	0.14	0.07
%Tipo	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
%No.	41	42								
%Tamaño	0.05	0.30;								
%Tipo	0.50	0.00								
	1;									

Para el entrenamiento, le indicamos en la variable “t”, donde se encuentra la separación de los datos negativos y positivos, y se le indicamos que los primero 21 datos de las dos hileras corresponden a cero (así separamos los negativos) y a los 21 sobrantes corresponden a unos (y los positivos); de esta manera vectoriza la correcta separación de los datos, mientras que en el entrenamiento realiza una especie de estadística para comparar posibles datos similares y clasificar según el parentesco. Ver Código 1.

Código 1. Indicación de la separación en los 42 melanomas.

```
7 t = [zeros(1,21) ones(1,21)];
```

Una vez que estén ingresados ya los 42 datos, el sistema lo que hace es reingresar nuevamente datos 100 veces, a esto se le denomina “Épocas”. Dentro del reingreso de datos se encuentra el buque que da lugar a la activación del entrenamiento en donde, los datos reconocen patrones que los hagan linealmente separables y calcular el error “e”. Ver Código 2.

Código 2. Entrenamiento del perceptrón con metadatos de ISIC.

```
15 for ITe = 1:100
16     for lp=1:length(p(1,:))
17         e(lp) = t(lp) - hardlim(W'*p(:,lp) + b);
18         W = W + e(lp)*p(:,lp);
19         b = b + e(lp);
20     end
21 end
```

3.2.3 Prueba del Perceptrón con Metadatos

En el caso de la prueba, se agregó la matriz con 40 datos; 20 malignos y 20 benignos, ya normalizados y separados con “;” el tamaño y el tipo de melanoma. Ver Tabla 7.

Tabla 7. Matriz de Prueba con 40 datos sacados de ISIC.

%No.	1	2	3	4	5	6	7	8	9	10
%Tamaño	0.30	0.18	0.32	0.16	0.20	0.89	0.23	0.05	0.18	0.34
%Tipo	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75
%No.	11	12	13	14	15	16	17	18	19	20
%Tamaño	0.14	0.23	0.25	0.09	0.20	0.08	0.14	0.07	0.05	0.30;
%Tipo	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.50	0.00;
	1;									

Al introducirse los datos nuevos al sistema, este, hace un reconocimiento de los patrones. De esta manera va repasando los datos de la matriz del entrenamiento y crea una frontera separable. En el caso que uno de los datos no sea reconocido, inmediatamente clasifica constando como error e indica que dato fue inconsistente dentro clasificación prueba. Ver Código 3.

Código 3. Lee la matriz de la nueva variable p y clasifica según el entrenamiento al que ya fue introducido.

```
46 for i=1:length(p(1,:))
47     c(i)= hardlim(W'*p(:,i) + b);
48 end
```

El resultado de la Red Neuronal Perceptrón se encuentra en *el capítulo 4* de resultados y conclusiones.

3.3 Backpropagation con Metadatos

Para el algoritmo de Backpropagation se tomó la misma matriz del *perceptrón con metadatos*. Se tomaron en cuenta 80 datos; 40 melanomas benignos y 40 malignos.

3.3.1 Valores Iniciales

Ya clasificados los ochenta metadatos (40 malignos y 40 benignos), se retoma la variable **P**, que se utilizara para el entrenamiento de la red neuronal. Ver Tabla 8.

Tabla 8. 80 metadatos de entrenamiento de los 2 atributos, tamaño y tipo en donde 40 son malignos y 40 benignos.

%No.		1	2	3	4	5	6	7	8	9	10
%Tamaño	P=[0.08	0.10	0.23	0.38	0.26	0.21	0.13	0.18	0.38	0.23
%Tipo		0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75
%No.		11	12	13	14	15	16	17	18	19	20
%Tamaño		0.74	0.23	0.28	0.10	0.23	0.08	0.05	0.03	0.03	0.03
%Tipo		0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75
%No.		21	22	23	24	25	26	27	28	29	30
%Tamaño		0.36	0.23	0.33	0.10	0.28	0.18	0.18	0.10	0.10	0.05
%Tipo		0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75
%No.		31	32	33	34	35	36	37	38	39	40
%Tamaño		0.28	0.12	0.23	0.10	0.23	0.26	0.15	0.26	0.08	0.05
%Tipo		0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75
%No.		41	42	43	44	45	46	47	48	49	50
%Tamaño		0.00	0.03	0.03	0.03	0.03	0.05	0.05	0.05	0.05	0.05
%Tipo		1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
%No.		51	52	53	54	55	56	57	58	59	60
%Tamaño		0.05	0.05	0.05	0.05	0.05	0.05	0.05	0.06	0.08	0.08
%Tipo		0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
%No.		61	62	63	64	65	66	67	68	69	70
%Tamaño		0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08	0.08
%Tipo		0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
%No.		71	72	73	74	75	76	77	78	79	80
%Tamaño		0.08	0.08	0.08	0.08	0.09	0.09	0.09	0.10	0.10	0.10
%Tipo		0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
];										

Para la entrada de los valores iniciales tenemos n es igual al número de neuronas que se otorga a la capa oculta. Ver Código 4. El algoritmo está compuesto por 3 capas “ $W1$ y $b1$ ”, “ $W2$ y $b2$ ” y “ $W3$ y $b3$ ”, cada capa contiene los valores iniciales de los pesos sinápticos. Ver Código 6.

Código 4. Numero de neuronas en la capa oculta.

```
15 n1 = 30;
```

Código 5. Ventana de valores iniciales.

```
17 ep = 1;
```

Código 6. Valores iniciales de los pesos sinápticos.

```
18 W1 = ep*(2*rand(n1,2)-1);  
19 b1 = ep*(2*rand(n1,1)-1);  
20 W2 = ep*(2*rand(1,n1)-1);  
22 b2 = ep*(2*rand-1);
```

3.3.2 Entrenamiento de la Red Neuronal Backpropagation con metadatos

Desde este momento se comienza con el entrenamiento de la red multicapa.

Se inicializa aleatoriamente las capas, desde 1 hasta hacer 100 épocas. Dentro del ciclo se encuentra la primera fase <<El patrón de entrada es presentado a la red y propagado a través de las capas hasta llegar a la capa de salida>>, de esta forma se propaga hacia enfrente. Ver Código 7.

Código 7. Propagación de la entrada hacia la salida.

```
31 a1 = tansig (W1*P(:,q) + b1);  
32 a2 = tansig (W2*a1 + b2);  
33 a3 = W3*a2 + b3;
```

Ya con los valores de salida de la primera fase, se inicia la segunda, <<comparándose estos valores con la salida esperada para así obtener el error>>. El algoritmo de **Retropropagación**, programa la sensibilidad de la última capa hacia la primera, *propaga hacia atrás*. Ver Código 8.

Código 8. Retropropagación de la sensibilidad.

```
36 e = T(q) - a3;  
37 s3 = -2*1*e;  
38 s2 = diag((1-a2).*a2)*W3'*s3;  
39 s1 = diag((1-a1).*a1)*W2'*s2;
```

3.3.3 Prueba

Para la prueba agregamos una nueva matriz con 40 melanomas en donde realiza el reconocimiento de los nuevos datos y separa los negativos de los positivos. Ver Código 9.

Código 9. Ciclo de reconocimiento de patrones.

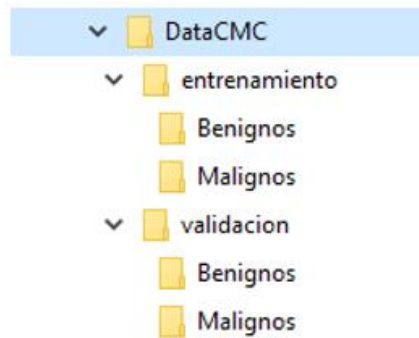
```
49 Aciertos = 0;  
50 for q = 1:Q  
51     [aprox(q) reconocidos(q)] = max(tansig(W2*tansig(W1*P(:,q) + b1) + b2));  
52     if (reconocidos(q) == 1)  
53         Aciertos = Aciertos + 1;  
54     end  
55 end
```

El resultado de la Red Neuronal Backpropagation se muestra en el Capítulo IV de Resultados de este trabajo de investigación

3.4 Red Neuronal Convolutacional con imágenes

3.4.2 Creación de los directorios para la Red Convolutacional

Se creó un origen de datos. En este caso fue DATACMC (datos con melanomas a color). Dentro de este directorio dos carpetas: Entrenamiento y Validación. Dentro de cada carpeta dos carpetas: Benignos y Malignos. Dentro de estos últimos las imágenes. Como se



observa en la Figura 28.

Figura 28. Contenido de la carpeta DataCMC.

Dentro de las carpetas se encuentra las imágenes correctamente clasificadas para el entrenamiento ya con tamaño de 100 x 100 píxeles. Ver Figura 29.

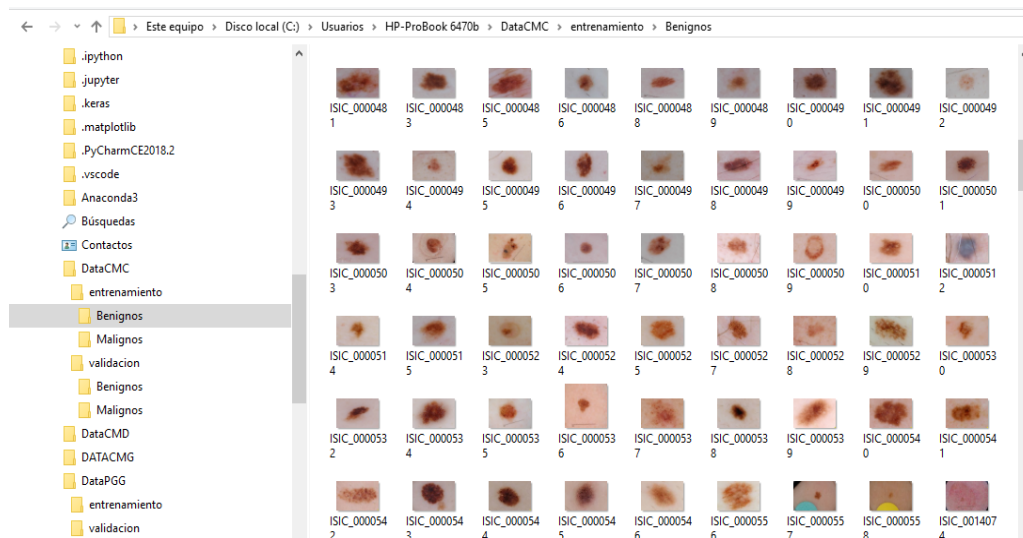


Figura 29. Contenido de la carpeta Benignos.

En la herramienta Jupyter se crea el programa para entrenar la Red Neuronal Convolutiva (RNC).

3.4.3 Algoritmo para la Red Neuronal Convolutiva

Las librerías necesarias para procesar el entrenamiento corresponden a Keras¹⁷ para Python de Tensorflow¹⁸. Ver la Código 10.

Código 10. Librerías para la Red Neuronal Convolutiva.

```

1 import sys
2 import os
3 from tensorflow.python.keras.preprocessing.image import ImageDataGenerator
4 from tensorflow.python.keras import optimizers
5 from tensorflow.python.keras.models import Sequential
6 from tensorflow.python.keras.layers import Dropout, Flatten, Dense, Activation
7 from tensorflow.python.keras.layers import Convolution2D, MaxPooling2D
9 from tensorflow.python.keras import backend as K

```

¹⁷ Herramienta para el desarrollo rápido en *deep learning* (redes neuronales)

¹⁸ Es una biblioteca de software libre que se utiliza para realizar cálculos numéricos mediante diagramas de flujo de datos

Para esto es preciso cargar los datos desde el directorio donde están las imágenes en nuestro equipo de trabajo. Ver Código 11.

Código 11. Cargar imágenes desde el directorio.

```
11 data_entrenamiento = './dataCMC/entrenamiento'  
12 data_validacion = './dataCMC/validacion'
```

Se determinan los parámetros para la RNC que dependen de las imágenes disponibles y el entrenamiento que deseamos llevar a cabo. Ver la Código 12.

Código 12. Determinación de los parámetros.

```
17 epocas=20  
18 altura, longitud = 100, 100  
19 batch_size = 32 #número de imágenes a procesar en cada uno de los pasos  
20 pasos = 1000 #1 epoca va a tener 1000 pasos  
21 pasos_validacion = 300  
22 filtrosConv1 = 32  
23 filtrosConv2 = 64  
24 tamaño_filtro1 = (3, 3)  
25 tamaño_filtro2 = (2, 2)  
26 tamaño_pool = (2, 2)  
27 clases = 2 #con carpetas  
28 lr = 0.0004#learnin right ajustes para que nuestra red aprenda
```

Antes del entrenamiento es necesario usar *ImageDataGenerator()* para preparar las imágenes, en este caso *rescale* se usa para que todas las imágenes tengan el mismo tamaño en píxeles. Los otros parámetros sirven para considerar imágenes alejadas o con rotación. También, *batch_size* sirve para procesar las imágenes por lotes, en este caso serán lotes de 32 imágenes. Ver la Código 13.

Código 13. Función *ImageDataGenerator()* y *Batch_size* para preparar las imágenes.

```
32 entrenamiento_datagen = ImageDataGenerator(  
33     rescale=1. / 255,  
34     shear_range=0.2,  
35     zoom_range=0.2,  
36     horizontal_flip=True)  
37  
38 validacion_datagen = ImageDataGenerator(rescale=1. / 255)  
39 imagen_entrenamiento = entrenamiento_datagen.flow_from_directory(  
40     data_entrenamiento,  
41     target_size=(altura, longitud),  
42     batch_size=batch_size,  
43     class_mode='categorical')  
44  
45 imagen_validacion= validacion_datagen.flow_from_directory(  
46     data_validacion,  
47     target_size=(altura, longitud),  
48     batch_size=batch_size,  
49     class_mode='categorical')
```

3.4.4 Entrenamiento de la Red Neurona Convolutiva

Finalmente se lleva a cabo el entrenamiento con una RNC de tipo secuencial, se lleva a cabo para imágenes 2D, se agrega el *maxpooling*¹⁹. Se aplanan la red neuronal con *flatten* para obtener un solo vector y proceder a la clasificación. La función *softmax()* permite elegir al vector que haya obtenido el mayor porcentaje para hacer la clasificación. Es decir, si el resultado es Imagen 1 24% y la imagen 2 es 76% *softmax* determina que gana la imagen 2. Ver Código 14.

¹⁹ Máxima Agrupación

Código 14. Algoritmo de aprendizaje de la Red Neuronal Convolucional.

```
51 cnn = Sequential()
52 cnn.add(Convolution2D(filtrosConv1, tamaño_filtro1, padding
53     ="same", input_shape=(altura, longitud, 3), activation='relu'))
54 cnn.add(MaxPooling2D(pool_size=tamaño_pool))
55 cnn.add(Convolution2D(filtrosConv2, tamaño_filtro2, padding
56     ="same", activation='relu'))
57
58 cnn.add(MaxPooling2D(pool_size=tamaño_pool))
59 cnn.add(Flatten())
60 cnn.add(Dense(256, activation='relu'))
61 cnn.add(Dropout(0.5))
62 cnn.add(Dense(clases, activation='softmax'))
63 cnn.compile(loss='categorical_crossentropy',
64     optimizer=optimizers.Adam(lr=lr),
65     metrics=['accuracy'])
66
67 cnn.fit_generator(imagen_entrenamiento, steps_per_epoch=pasos, epochs
68     =epocas, verbose=1, callbacks=None,
69     validation_data=imagen_validacion,
70     validation_steps=pasos_validacion)
```

El conocimiento del entrenamiento debe almacenarse en archivos para poder usarse en el reconocimiento. Ver la Código 15.

Código 15. Algoritmo de almacenamiento para reconocimiento de archivos.

```
72 target_dir = './modeloCMC/'
73 if not os.path.exists(target_dir):
74     os.mkdir(target_dir)
75 cnn.save('./modeloCMC/modelo.h5')
76 cnn.save_weights('./modeloCMC/pesos.h5')
77 cnn.save('./modeloCMC/modelo.csv')
```

Al ejecutarse creará una carpeta con dos archivos: Modelo.H5, y Pesos.H5. Ver

Figura 30.




C:) > Usuarios > HP-ProBook 6470b > modeloCMC				
Nombre	Fecha de modifica...	Tipo	Tamaño	
 modelo	14/10/2018 12:34 a...	Archivo de valores...	120,153 KB	
 modelo	14/10/2018 12:34 a...	Archivo H5	120,153 KB	
 pesos	14/10/2018 12:34 a...	Archivo H5	40,059 KB	

Figura 30. Archivo Modelo.H5 y Peso.H5

3.4.5 Prueba

Continuamos con la creación del programa para hacer la predicción del pre-diagnóstico de melanomas. Ver Código 16.

Código 16. Algoritmo de predicción del pre-diagnóstico.

```

1 import numpy as np
2 from tensorflow.python.keras.preprocessing.image import load_img, img_to_array
3 from tensorflow.python.keras.models import load_model
4
5 longitud, altura = 100, 100
6 modelo = './modeloCMG/modelo.h5'
7 pesos_modelo = './modeloCMC/pesos.h5'
8 cnn = load_model(modelo)
9 cnn.load_weights(pesos_modelo)
10
11 def predict(file):
12     x = load_img(file, target_size=(longitud, altura))
13     x = img_to_array(x)
14     x = np.expand_dims(x, axis=0)
15     array = cnn.predict(x)
16     result = array[0]
17     answer = np.argmax(result)
18     if answer == 0:
19         print("pred: Benigno")
20 elif answer == 1:
21     print("pred: Maligno")

```


El algoritmo de predicción recibe una o más imágenes y las clasifica mediante el conocimiento almacenado en el “Modelo” y “Pesos”. La salida deberá ser la esperada. Ver la Código 17.

Código 17. Impresión del pre-diagnóstico.

```

1  print ("Melanomas malignos -----
2  -----")
3
4  MyImage = 'C:/Users/HP-ProBook
5  6470b/DataCMC/validacion/Malignos/ISIC_0012070.jpg'
6  predict (MyImage)
7  MyImage = 'C:/Users/HP-ProBook
8  6470b/DataCMC/validacion/Malignos/ISIC_0012074.jpg'
9  predict (MyImage)
10 MyImage = 'C:/Users/HP-ProBook
11 6470b/DataCMC/validacion/Malignos/ISIC_0012079.jpg'
12 predict (MyImage)
13 MyImage = 'C:/Users/HP-ProBook
14 6470b/DataCMC/validacion/Malignos/ISIC_0012083.jpg'
15 predict (MyImage)
16 MyImage = 'C:/Users/HP-ProBook
17 6470b/DataCMC/validacion/Malignos/ISIC_0012151.jpg'
18 predict (MyImage)
19 MyImage = 'C:/Users/HP-ProBook
20 6470b/DataCMC/validacion/Malignos/ISIC_0012258.jpg'
21 predict (MyImage)
22 MyImage = 'C:/Users/HP-ProBook
23 6470b/DataCMC/validacion/Malignos/ISIC_0012348.jpg'
24 predict (MyImage)
25 MyImage = 'C:/Users/HP-ProBook
26 6470b/DataCMC/validacion/Malignos/ISIC_0012290.jpg'
27 predict (MyImage)

```

```

28 MyImage = 'C:/Users/HP-ProBook
29 6470b/DataCMC/validacion/Malignos/ISIC_0012512.jpg'
30 predict (MyImage)
31 MyImage = 'C:/Users/HP-ProBook
32 6470b/DataCMC/validacion/Malignos/ISIC_0012678.jpg'
33 predict (MyImage)
34
35 print ("Melanomas benignos -----
36 -----")
37
38 MyImage = 'C:/Users/HP-ProBook
39 6470b/DataCMC/validacion/Benignos/ISIC_0014498.jpg'
40 predict (MyImage)
41 MyImage = 'C:/Users/HP-ProBook
42 6470b/DataCMC/validacion/Benignos/ISIC_0014475.jpg'
43 predict (MyImage)
44 MyImage = 'C:/Users/HP-ProBook
45 6470b/DataCMC/validacion/Benignos/ISIC_0014430.jpg'
46 predict (MyImage)
47 MyImage = 'C:/Users/HP-ProBook
48 6470b/DataCMC/validacion/Benignos/ISIC_0014409.jpg'
49 predict (MyImage)
50 MyImage = 'C:/Users/HP-ProBook
51 6470b/DataCMC/validacion/Benignos/ISIC_0014397.jpg'
52 predict (MyImage)
53 MyImage = 'C:/Users/HP-ProBook
54 6470b/DataCMC/validacion/Benignos/ISIC_0014310.jpg'
55 predict (MyImage)
56 MyImage = 'C:/Users/HP-ProBook
57 6470b/DataCMC/validacion/Benignos/ISIC_0014341.jpg'
58 predict (MyImage)
59 MyImage = 'C:/Users/HP-ProBook
60 6470b/DataCMC/validacion/Benignos/ISIC_0014158.jpg'
61 predict (MyImage)
62 MyImage = 'C:/Users/HP-ProBook
63 6470b/DataCMC/validacion/Benignos/ISIC_0014139.jpg'

```

```
64 predict (MyImage)
65 MyImage = 'C:/Users/HP-ProBook
66 6470b/DataCMC/validacion/Benignos/ISIC_0014150.jpg'
67 predict (MyImage)
```

La salida de la predicción se muestra en el Capítulo IV de Resultados de este trabajo de investigación

Capítulo IV Resultados y Conclusiones

4.1 Resultados

4.1.1 Red Neuronal Perceptrón con Metadatos

Como resultado del entrenamiento, en la Figura 31, se puede observar que el sistema esta linealmente separado. Agrupo los dos campos (*los melanomas malignos simulados por el asterisco azul “*” y los benignos por los rombos verdes “◇”*), dependiendo a sus dimensiones que se ingresaron en la variable “*p*”.

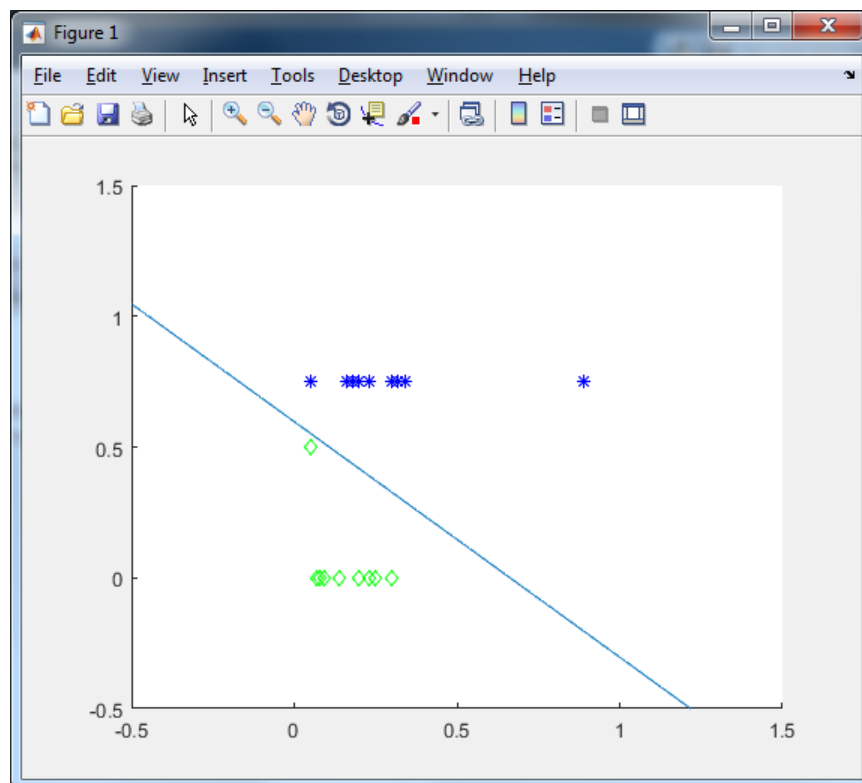


Figura 31. Gráfica del entrenamiento del perceptrón con metadatos.

Para el resultado de la prueba, tiene un porcentaje de acierto del 95%, esto es causado, por una pequeña similitud en uno de los datos ingresados, ya que la frontera de separación no concuerda con las estadísticas de algunos datos. Como se puede observar en la Figura 32. La gráfica separa correctamente los datos a excepción de uno.




Figura 32. Gráfica de la prueba del perceptrón con metadatos.

Por otra parte, se realizó una prueba cruzando datos, es decir, que se los datos se intercambiaron (el entrenamiento cambio a la prueba y la prueba al entrenamiento); y el resultado vario muy poco, en el caso del nuevo entrenamiento separo correctamente, pero tuvo un ligero acercamiento con uno de los datos, aun así, fue linealmente separable. Ver la Figura 33.




Figura 33. Gráfica linealmente separable del perceptrón con metadatos utilizando los datos de la prueba (perceptrón cruzado).

Sin embargo, para la nueva prueba tubo un acierto del 88%, recordado que la prueba se intercambi6 con el entrenamiento y en esta prueba aumento el margen de error a un 12 % ya que al tener m6s datos que el entrenamiento, no clasific6 los pocos datos que no encontr6 en su nuevo entrenamiento. Ver Figura 34.




Figura 34. Gráfica linealmente separable del perceptrón con metadatos utilizando los datos del entrenamiento (perceptrón cruzado).

4.1.2 Red Neuronal Backpropagation con metadatos

En el caso de la red neuronal Backpropagation, separó los metadatos del entrenamiento, acertando un porcentaje del 100%, mientras en la prueba clasificó 38 de 40 datos clasificando un 95% de los metadatos como se muestra en la Figura 35.

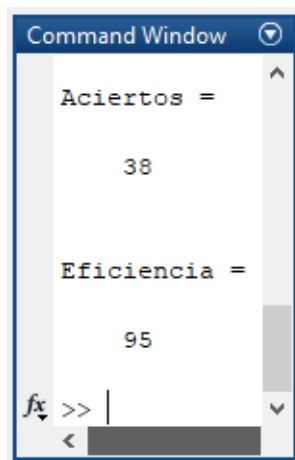


Figura 35. Impresión de pantalla de la ventana de comandos de Matlab.

Como se muestra en la Figura 36, el margen de error está descendiendo a 0, esto referencia que la escalabilidad es buena.




Figura 36. Margen de Error del Backpropagation con metadatos.

Aclarando que los círculos “O” representan a los melanomas maligno y los círculos azules “O” melanomas benignos.

Como se observa en la Figura 37, se muestra la clasificación de la prueba que realiza la red neuronal, da como resultado que los melanomas malignos sean correctamente clasificados, a lo contrario de los benignos; como lo vimos con el perceptrón con metadatos, uno de los datos tiene una inconsistencia que ni fue clasificada incluso para el Backpropagation obtuvo el mismo resultado sin clasificación de este, dando como resultado un porcentaje del 95% al igual que el perceptrón.




Figura 37. Gráfica de clasificación de la red neuronal Backpropagation con metadatos.

4.1.3 Red Neuronal Convolutacional

Como muestra en la Tabla 9, al ejecutarse la salida de predicción, dio como resultado en los melanomas malignos un 100% acertando 10 de 10 en la validación; sin embargo, en los benignos muestra una predicción del 90% acertando 9 de 10 en la misma.

Tabla 9. Tabla de Resultado del Pre- diagnóstico.

Melanomas malignos -----

pred: Maligno
pred: Maligno
pred: Maligno
pred: Maligno
pred: Maligno
pred: Maligno
pred: Maligno
pred: Maligno
pred: Maligno
pred: Maligno
Melanomas benignos -----

pred: Benigno
pred: Benigno
pred: Benigno
pred: Benigno
pred: Benigno
pred: Benigno
pred: Benigno
pred: Maligno
pred: Benigno
pred: Benigno

En este caso predijo correctamente 19 de 20 imágenes, que corresponde al 95%.

Para mejorar la precisión se requieren dos cosas:

- a) más imágenes: un mínimo de 1000.
- b) más entrenamiento: aumentar las épocas y Pasos del algoritmo.

Mientras tanto, como se observa en la Tabla 10, al correr el programa podemos observar las 20 épocas que realiza la Red Neuronal Convolutacional, donde explica, el

porcentaje de error ascendiendo a cero (loss), porcentaje de reconocimiento (acc) del entrenamiento, porcentaje de error ascendiendo a cero (val_loss) y porcentaje de reconocimiento (val_acc) de la prueba dándonos resultado un reconocimiento del 95%.

Tabla 10. Resultado de la compilación de la red Neuronal Convolutional

Found 240 images belonging to 2 classes.				
Found 120 images belonging to 2 classes.				
Epoch 1/20				
1000/1000	- 884s	884ms/step	- loss: 0.2520	- acc: 0.8982 - val_loss: 0.0923 - val_acc: 0.9667
Epoch 2/20				
1000/1000	- 907s	907ms/step	- loss: 0.0708	- acc: 0.9764 - val_loss: 0.0131 - val_acc: 1.0000
Epoch 3/20				
1000/1000	- 889s	889ms/step	- loss: 0.0259	- acc: 0.9920 - val_loss: 0.0029 - val_acc: 1.0000
Epoch 4/20				
1000/1000	- 880s	880ms/step	- loss: 0.0180	- acc: 0.9944 - val_loss: 0.0247 - val_acc: 0.9833
Epoch 5/20				
1000/1000	- 883s	883ms/step	- loss: 0.0184	- acc: 0.9940 - val_loss: 7.4845e-05 - val_acc: 1.0000
Epoch 6/20				
1000/1000	- 879s	879ms/step	- loss: 0.0165	- acc: 0.9945 - val_loss: 3.6300e-04 - val_acc: 1.0000
Epoch 7/20				
1000/1000	- 882s	882ms/step	- loss: 0.0078	- acc: 0.9975 - val_loss: 0.0015 - val_acc: 1.0000
Epoch 8/20				
1000/1000	- 883s	883ms/step	- loss: 0.0099	- acc: 0.9966 - val_loss: 7.4416e-05 - val_acc: 1.0000
Epoch 9/20				
1000/1000	- 899s	899ms/step	- loss: 0.0096	- acc: 0.9969 - val_loss: 2.0403e-04 - val_acc: 1.0000
Epoch 10/20				
1000/1000	- 897s	897ms/step	- loss: 0.0052	- acc: 0.9985 - val_loss: 8.6192e-04 - val_acc: 1.0000
Epoch 11/20				
1000/1000	- 896s	896ms/step	- loss: 0.0127	- acc: 0.9961 - val_loss: 4.8508e-05 - val_acc: 1.0000
Epoch 12/20				
1000/1000	- 886s	886ms/step	- loss: 0.0024	- acc: 0.9992 - val_loss: 1.5652e-06 - val_acc: 1.0000
Epoch 13/20				
1000/1000	- 883s	883ms/step	- loss: 0.0108	- acc: 0.9969 - val_loss: 5.7584e-05 - val_acc: 1.0000
Epoch 14/20				
1000/1000	- 886s	886ms/step	- loss: 0.0042	- acc: 0.9987 - val_loss: 2.3264e-05 - val_acc: 1.0000
Epoch 15/20				
1000/1000	- 885s	885ms/step	- loss: 0.0044	- acc: 0.9987 - val_loss: 4.9025e-07 - val_acc: 1.0000
Epoch 16/20				
1000/1000	- 879s	879ms/step	- loss: 0.0068	- acc: 0.9979 - val_loss: 1.6009e-06 - val_acc: 1.0000
Epoch 17/20				
1000/1000	- 878s	878ms/step	- loss: 0.0069	- acc: 0.9978 - val_loss: 2.6843e-06 - val_acc: 1.0000
Epoch 18/20				
1000/1000	- 897s	897ms/step	- loss: 0.0071	- acc: 0.9980 - val_loss: 3.5398e-05 - val_acc: 1.0000
Epoch 19/20				
1000/1000	- 898s	898ms/step	- loss: 0.0036	- acc: 0.9989 - val_loss: 2.3349e-05 - val_acc: 1.0000
Epoch 20/20				
1000/1000	- 893s	893ms/step	- loss: 0.0079	- acc: 0.9978 - val_loss: 1.9148e-05 - val_acc: 1.0000

En la Tabla 11 mostramos el porcentaje de eficiencia de cada uno de las Redes Neuronales de este Proyecto

Tabla 11. Comparación del porcentaje de eficiencia de cada Red Neuronal

Red Neuronal	Porcentaje de Eficiencia Entrenamiento	Porcentaje de Eficiencia Validación
Red Neuronal Perceptrón con Metadatos	100%	95%
Red Neuronal Perceptrón con Metadatos (Cruzada)	100%	88%
Red Neuronal Backpropagation con Metadatos	100%	95%
Red Neuronal Convolutacional con Imágenes	99%	95%

4.2 Conclusiones

4.2.1 Red Neuronal Perceptrón con metadatos

En el caso del perceptrón con metadatos, se obtiene un mejor comportamiento en la clasificación de los melanomas utilizando metadatos en vez de imágenes; sin embargo, el perceptrón solo clasifica si hay una frontera linealmente separable, esto lo hace vulnerable al no poder separar las acepciones que pueden ser clasificadas.

El perceptrón con metadatos es aceptable para un pre-diagnóstico, pero no es la mejor opción ya que el perceptrón no es tan complejo como las otras redes neuronales

4.2.2 Red Neuronal Backpropagation con metadatos

Para el Backpropagation con metadatos, al igual que el perceptrón con metadatos, hay un mejor comportamiento utilizando datos comparación de imágenes: Por otra parte, a lo contrario del perceptrón, backpropagation tiene un sistema más completo ya que no es un clasificador lineal y puede agrupar datos obteniendo una clasificación más exacta que el perceptrón. Otra ventaja de Backpropagation es el tiempo de respuesta es más óptimo que a

comparación de la Red Neurona Adaline y la Red Neurona Convolutiva, sus tiempos de respuesta tardan horas.

Backpropagation es un sistema óptimo para el desarrollo del pre-diagnóstico, pero cabe destacar que al utilizar metadatos su comportamiento es bueno.

4.2.3 Red Neuronal Convolutiva con imágenes

La Red Neuronal Convolutiva permite predecir si un melanoma es benigno o maligno a partir de un gran número de imágenes. La desventaja es que requiere muchas horas para llevar a cabo el entrenamiento. Entre más imágenes, épocas y/o pasos, tenga el algoritmo, este tardará horas obtener una respuesta. La ventaja es que la precisión es muy alta.

Capítulo V Referencias

- [1] C. Burr, A. Piñó, L. A. Quiroz y . E. Martín-Lunas, Guía para el paciente participativo, Mexico: LID, 2011.
- [2] C. Gonzalez, «La piel.com,» 23 Junio 2004. [En línea]. Available: http://www.lapiel.com/frontend/lapiel/noticia.php?id_noticia=558.
- [3] J. Lorente, «La radiación solar,» [En línea]. Available: <http://www.portalfarma.com/Profesionales/campanaspf/categorias/Documents/MAQUETACION%20MATERIAL%20FORMATIVO%20fotoproteccionfotproc2010.pdf>.
- [4] UPAEP. [En línea].
- [5] D. Baez Lopez y O. Cervantes Villagomez, Matlab con aplicaciones a la Ingeniería, Física y Finanzas, Alfaomega, 2012.
- [6] A. M. Fernandez, Python 3 al descubierto, México: Alfaomega, 2012.
- [7] A. Marzal y I. Gracia, Introducción a la Programación.
- [8] C. ©. 2. P. Jupyter, «Jupyter.org,» Copyright ©, 21 octubre 2018. [En línea]. Available: <http://jupyter.org/about>. [Último acceso: 05 Noviembre 2018].
- [9] «Jupyter.org,» Copyright © 2018, 21 Octubre 2018. [En línea]. Available: <http://jupyter.org/>. [Último acceso: 26 Octubre 2018].
- [10] A. M. C. y O. F., «Introducción a los Básicos de la Teoría General de Sistema,» 1998. [En línea]. Available: <http://www.redalyc.org/articulo.oa?id=10100306>.
- [11] N. M. Cruz, «DESARROLLO DE UN SISTEMA AVANZADO DE ASISTENCIA A LA CONDUCCIÓN EN TIEMPO REAL PARA LA DETECCIÓN DE PEATONES EN ENTORNOS URBANOS COMPLEJOS,» marzo 2013. [En línea]. Available: https://e-archivo.uc3m.es/bitstream/handle/10016/17162/PFC_Natalia_Moran_Cruz.pdf. [Último acceso: 27 febrero 2018].
- [12] DeConceptos.com, «DeConceptos.com,» 2017. [En línea]. Available: <http://deconceptos.com/general/imagen>.
- [13] J. J. Esqueda Elizondo, «Fundamentos de Procesamiento de Imágenes,» Noviembre 2002. [En línea]. Available: http://www.academia.edu/16801512/Fundamentos_de_procesamiento_de_im%C3%A1genes_digitales. [Último acceso: 12 Diciembre 2018].
- [14] P. F. Posada, «Diseño de Materiales Multimedia _ web 2.0,» 2008. [En línea]. Available:

- <http://www.ite.educacion.es/formacion/materiales/107/cd/imagen/pdf/imagen01.pdf>.
- [15] URSEC, «Universidad Reguladora de Servicios de Comunicaciones,» [En línea]. Available: https://www.ursec.gub.uy/wps/wcm/connect/ursec/21d07f74-c3ca-4a11-a240-edecda3c447c/6_Definiciones+y+conceptos.pdf?MOD=AJPERES&CONVERT_TO=url&CACHEID=21d07f74-c3ca-4a11-a240-edecda3c447c.
- [16] L. Alegsa, «Alegsa,» 04 Julio 2016. [En línea]. Available: <http://www.alegsa.com.ar/Dic/pixel.php>.
- [17] J. R. Mejía Vilet, «Procesamiento Digital de Imágenes,» enero 2005. [En línea]. Available: http://read.pudn.com/downloads159/ebook/711796/Procesamiento_Digital_de_Imagenes.pdf.
- [18] M. A. Valencia Reyes, C. Yáñez Márquez y L. P. Sanchez Fernandez, «Algoritmo Backpropagation para Redes Neuronales: conceptos y aplicaciones,» 2006. [En línea]. Available: <http://repositoriodigital.ipn.mx/bitstream/123456789/8628/1/Archivo%20que%20incluye%20portada,%20C3%ADndice%20y%20texto.pdf>.
- [19] F. Lara Rosano, «FUNDAMENTOS DE REDES NEURONALES ARTIFICIALES,» [En línea]. Available: http://conceptos sociales.unam.mx/conceptos_final/598trabajo.pdf. [Último acceso: 2018 MAYO 17].
- [20] D. Jorge Matich, «Redes Neuronales: Conceptos Básicos y Aplicaciones,» MARZO 2001. [En línea]. Available: https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monografias/matich-redesneuronales.pdf. [Último acceso: 17 MAYO 2018].
- [21] J. A. Anderson, Redes Neuronales, Mexico: Alfaomega Grupo Editor, S. A. de C. V., 2007.
- [22] J. Durán Suarez, «Redes Neuronales Convolucionales en R,» 2017. [En línea]. Available: <http://bibing.us.es/proyectos/abreproy/91338/fichero/TFG+Jaime+Dur%C3%A1n+Su%C3%A1rez.pdf>. [Último acceso: 24 oct 2018].
- [23] O. E. Contreras Zaragoza, «Desarrollo de una red neuronal convolucional para el procesamiento de imágenes placentarias,» 2018. [En línea]. Available: <http://www.ptolomeo.unam.mx:8080/xmlui/bitstream/handle/132.248.52.100/15458/tesis.pdf?sequence=1>. [Último acceso: 2018 oct 24].
- [24] M. Y. Ríos, «Introducción a la dermatología,» 2017. [En línea]. Available: <http://www.telmeds.org/wp-content/uploads/2011/03/INTRODUCCION-A-LA->

DERMATOLOGIA.pdf.

- [25] A. Túnez, «CCM Benchmark,» 2017. [En línea]. Available: <http://salud.ccm.net/faq/12707-dermatologia-definicion>.
- [26] UNLP, «Semiología dermatológica,» 2017. [En línea]. Available: http://www.med.unlp.edu.ar/material/dermatologia/1.LESIONES_ELEMENTALES.PDF.
- [27] M. Pérez, «La radiación solar y sus efectos fotobiológicos sobre la piel humana,» [En línea]. Available: <http://www.portalfarma.com/Profesionales/campanaspf/categorias/Documents/MAQUETACION%20MATERIAL%20FORMATIVO%20fotoproteccionfotproc2010.pdf>.
- [28] «Instituto Nacional del Cáncer,» 25 Abril 2012. [En línea]. Available: <http://www.cancer.gov/espanol/publicaciones/diccionario?cdrid=46290>.
- [29] H. D. Fuentes, «El Medico Oncologo,» [En línea]. Available: <http://oncocenter.galeon.com/oncologo1.html>.
- [30] J. Puente y G. de Velasco, «SEOM Sociedad española de Oncología Medica,» 2017. [En línea]. Available: <http://www.seom.org/en/informacion-sobre-el-cancer/que-es-el-cancer-y-como-se-desarrolla>.
- [31] «Organización Mundial de la Salud,» 2017. [En línea]. Available: <http://www.who.int/topics/cancer/es/>.
- [32] I. N. NIH, «MedlinePlus,» 2017. [En línea].
- [33] «enciclopediasalud.com,» 16 Abril 2016. [En línea]. Available: <http://www.enciclopediasalud.com/definiciones/melanocitos>.