



UNIVERSIDAD JOSÉ ANTONIO PÁEZ

**DESARROLLO DE UN SISTEMA DE
IDENTIFICACIÓN DE MELANOMAS
EN LA PIEL A PARTIR DE IMÁGENES
BASADO EN REDES NEURONALES
CONVOLUCIONALES**

Autor:

Santiago Antonio Aure Celli

Urb. Yuma II, Calle N° 3, Municipio San Diego
Teléfono: (0241) 8714240 (Máster) - Fax: (0241) 8712394



REPÚBLICA BOLIVARIANA DE VENEZUELA
UNIVERSIDAD JOSÉ ANTONIO PÁEZ
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA EN COMPUTACIÓN

**DESARROLLO DE UN SISTEMA DE IDENTIFICACIÓN DE
MELANOMAS EN LA PIEL A PARTIR DE IMÁGENES BASADO EN
REDES NEURONALES CONVOLUCIONALES**
Proyecto del Trabajo de Grado para optar al título de
INGENIERO EN COMPUTACIÓN

Autor:

Santiago Antonio Aure Celli

Tutora:

Ing. Rosa Ortega

San Diego, septiembre de 2022



UNIVERSIDAD JOSÉ ANTONIO PÁEZ
COORDINACIÓN DE PASANTÍA Y TRABAJO DE GRADO

ACTA DE APROBACIÓN

INFORME FINAL DE PASANTÍA

TRABAJO DE GRADO

El jurado designado por la Facultad de Ingeniería para la evaluación del Informe Final de Pasantía o Trabajo de Grado titulado:

Desarrollo de un Sistema de Identificación de Melanomas en la Piel a Partir de Imágenes Basado en Redes Neuronales Convolucionales.

Realizado por el (la) Br. Santiago Anbrío Aure


C.I. N° 26.581.678 cursante de la carrera de Ingeniería en Computación

hace constar después de analizar su contenido y oída la exposición oral, considera que el Informe Final o Trabajo de Grado ha obtenido la calificación de:


APROBADO

NO APROBADO

El Jurado


Tutor Académico (Coordinador)
Nombre: Walter Orjeda
C.I.: 944720


Jurado
Nombre: Mylbet Rodríguez
C.I.: 7996228


Jurado
Nombre: Wiston Espinoza
C.I.: 9885895

Fecha: 14 / 10 / 2022





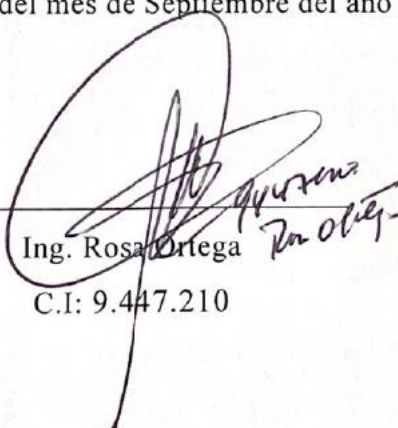


REPÚBLICA BOLIVARIANA DE VENEZUELA
UNIVERSIDAD JOSÉ ANTONIO PÁEZ
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA DE COMPUTACIÓN

**CONSTANCIA DE APROBACIÓN PARA LA PRESENTACIÓN
PÚBLICA DEL TRABAJO DE GRADO**

Quien suscribe, Ing. Rosa Ortega, portador de la cédula de identidad N° 9.447.210, en mi carácter de tutor del trabajo de grado presentado por el ciudadano Santiago Aure, portador de la cédula de identidad N° 26.581.678, titulado **“DESARROLLO DE UN SISTEMA DE IDENTIFICACIÓN DE MELANOMAS EN LA PIEL A PARTIR DE IMÁGENES BASADO EN REDES NEURONALES CONVOLUCIONALES.”**, presentado como requisito parcial para optar al título de Ingeniero de Computación, considero que dicho trabajo reúne los requisitos y méritos suficientes para ser sometido a la presentación pública y evaluación por parte del jurado examinador que se designe.

En San Diego, a los 14 días del mes de Septiembre del año dos mil veintidós.


Ing. Rosa Ortega

C.I: 9.447.210

UNIVERSIDAD JOSÉ ANTONIO PÁEZ
FACULTAD DE INGENIERÍA
DECANATO DE INGENIERÍA



FI C 003 2022-2CR TG

Valencia, 10 de junio de 2022

Ciudadano:
AURE CELLI, SANTIAGO ANTONIO
26.581.678
Presente -

Cumplo con informarle que la comisión de Trabajo de Grado y Pasantías de la Facultad de Ingeniería en su reunión N° 7-2022 de fecha 13/05/2022 aprobó el proyecto de grado titulado:

Desarrollo de un sistema de identificación de melanomas en la piel a partir de imágenes basado en redes neuronales convolucionales.

Presentado por usted como requisito para optar al título de Ingeniero en Computación.

Se ratifica la designación del Tutor Académico que lo asesorará en el desarrollo de este proyecto a:
Ing. Rosa Virginia Ortega Loaiza, titular de la cédula de identidad V-9.447.210



Atentamente

Dr. Francisco Gelanzé Sevilla.
Decano de Ingeniería

c.c. Coordinación de Pasantías y Trabajo de Grado

ÍNDICE GENERAL

RESUMEN INFORMATIVO	XI
INTRODUCCIÓN	1
CAPÍTULO I	3
EL PROBLEMA	3
1.1. Planteamiento del problema.....	3
1.2. Formulación del problema	5
1.3. Objetivos de la investigación	5
1.3.1. Objetivo general	5
1.3.2. Objetivos específicos	5
1.4. Justificación de la investigación.....	6
1.5. Alcance y Limitaciones.....	7
CAPÍTULO II	8
MARCO TEÓRICO	8
2.1. Antecedentes de la investigación	8
2.2. Bases teóricas	11
2.2.1. Sistema	11
2.2.2. Melanoma.....	11
2.2.3. Aprendizaje de Máquina	12
2.2.4. Redes Neuronales Artificiales.....	13
2.2.5. Redes Neuronales Convolucionales.....	14
2.2.6. Arquitectura de Redes Neuronales Convolucionales.....	14
2.2.7. Teoría de la computabilidad.....	16
2.3. Bases legales	16
2.4. Definición de términos básicos	17
CAPÍTULO III	20
MARCO METODOLÓGICO	20

3.1. Tipo de investigación	20
3.2. Diseño de la investigación	20
3.3. Nivel de la investigación.....	21
3.4. Población y muestra	21
Tomando en cuenta la definición dada por Arias, quien señala que:.....	21
3.5. Técnicas e instrumentos de recolección de datos.....	22
3.6. Fases metodológicas.....	23
CAPÍTULO IV	26
RESULTADOS.....	26
4.1. Fase I: Cuantificación de las variables que intervienen en la identificación de melanomas en la piel.	26
4.1.1 Actividad I: Investigación de sistemas con similitudes a la plataforma que se planteó desarrollar.....	27
4.1.2 Actividad II: Elaboración del guion para la entrevista y aplicación. ...	27
4.2. Fase II: Determinación de los requerimientos funcionales y no funcionales inherentes al sistema de verificación de la presencia de patología en el tejido. 37	
4.2.1. Actividad I: Análisis y definición de los requisitos funcionales y no funcionales del sistema.	37
4.3. Fase III: Desarrollo de la arquitectura de red neuronal más apropiada para el reconocimiento de las lesiones.	38
4.3.1. Actividad I: Diseño de la red neuronal	38
4.3.2. Actividad II: Codificación de la red neuronal.....	40
4.4. Fase IV: Entrenamiento de la red neuronal dándole muestras de imágenes mostrando lunares benignos y melanomas cancerígenos.	41
4.4.1 Actividad I: Determinación de las imágenes para entrenamiento y validación.	41
4.4.2 Actividad II: Determinación de una velocidad de entrenamiento óptima.	43
4.4.3 Actividad III: Determinación de los hiper parámetros adecuados.	46

4.4.4. Actividad IV: entrenamiento de la red neuronal con los valores obtenidos.	49
4.5. Fase V: Realización de pruebas a la red neuronal ingresando imágenes ya clasificadas y comparando los resultados dados por la red con el diagnostico ya establecido.....	51
4.5.1. Actividad I: Implementación de la red en un programa local con interfaz.....	52
CONCLUSIONES Y RECOMENDACIONES.....	55
Conclusiones	55
Recomendaciones.....	57
REFERENCIAS BIBLIOGRÁFICAS.....	58

ÍNDICE DE TABLAS

Tabla 1. Respuesta pregunta n° 1 entrevista.	27
Tabla 2. Respuesta pregunta n° 2 entrevista.	29
Tabla 3. Respuesta pregunta n° 3 entrevista.	31
Tabla 4. Respuesta pregunta n° 4 entrevista.	32
Tabla 5. Respuesta pregunta n° 5 entrevista.	34
Tabla 6. Respuesta pregunta n° 6 entrevista.	34
Tabla 7. Respuesta pregunta n° 7 entrevista.	35
Tabla 8. Respuesta pregunta n° 8 entrevista.	36

ÍNDICE DE GRÁFICOS

Gráfico 1. Compund scaling.	39
Gráfico 2. Arquitectura de la red neuronal.	40
Gráfico 3. Implementación de la arquitectura de la red en código.	41
Gráfico 4. Imágenes luego de aplicar data augmentation.	42
Gráfico 5. Implementación del cyclic learning rate scheduler (1).	44
Gráfico 6. Implementación del cyclic learning rate scheduler (2).	45
Gráfico 7. Implementación del cyclic learning rate scheduler (3).	46
Gráfico 8. Definición de función constructora del modelo con parámetros variables para la aplicación de keras.tuner.	48
Gráfico 9. Inicialización del buscador de hiper parámetros óptimos.	48
Gráfico 10. Retornos de la función tuner.search (1)	49
Gráfico 11. Retornos de la función tuner.search (2)	49
Gráfico 12. Función de pérdida durante el entrenamiento.	50
Gráfico 13. Función de precisión durante el entrenamiento.	50
Gráfico 14. Interfaz inicial del sistema.	52
Gráfico 15. Interfaz del sistema con predicción exitosa de lunar emitida.	53
Gráfico 16. Interfaz del sistema con predicción exitosa de melanoma emitida.	54



**REPÚBLICA BOLIVARIANA DE VENEZUELA
UNIVERSIDAD JOSÉ ANTONIO PÁEZ
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA EN COMPUTACIÓN**

**DESARROLLO DE UN SISTEMA DE IDENTIFICACIÓN DE
MELANOMAS EN LA PIEL A PARTIR DE IMÁGENES BASADO EN
REDES NEURONALES CONVOLUCIONALES**

Autor: Santiago Antonio Aure Celli
Tutora: Ing. Rosa Ortega
Fecha: Septiembre 2022

RESUMEN INFORMATIVO

El presente proyecto tiene como objetivo general el desarrollo de un sistema de identificación de melanomas a partir de imágenes basado en redes neuronales convolucionales. El fin de lo anteriormente mencionado es lograr un diagnóstico rápido y confiable ante la sospecha de la presencia de melanoma en el paciente. Para ello se realizó la presente investigación enmarcada en el modelo de proyecto especial, con un diseño de campo para recolección de información, paralelamente se hizo uso de la metodología de desarrollo XP. Aunado a ello, se realiza enfocado en la línea de investigación desarrollo de nuevas tecnologías de la información y comunicación, en una investigación de tipo proyecto especial con un diseño documental con enfoque mixto y un nivel descriptivo. Las técnicas de recolección de datos fueron la recopilación documental y la entrevista. Para finalizar, se desarrollará un sistema que permitiría el procesamiento de imágenes de lesiones en la piel ingresadas por el usuario de manera tal que las clasifique en benignas o malignas.

Descriptor: Melanoma, redes neuronales convolucionales, aprendizaje profundo

INTRODUCCIÓN

El proceso de diagnóstico de un melanoma generalmente se lleva a cabo en dos pasos: primero se revisa el historial médico del paciente consultor, y se realiza un examen físico del área de la cual se sospecha que pueda poseer una lesión, en búsqueda de signos que puedan indicar la presencia de un melanoma. Al ser esta primera revisión poco certera a la hora de emitir un diagnóstico, se prosigue con el segundo paso, que es la extracción de una muestra de tejido para analizarla.

La clave del éxito en este diagnóstico para los pacientes es la detección pronta de la lesión en la piel. Para ello se ha hecho divulgación de nemotecnias como ABCDE, refiriéndose a los aspectos de la marca potencialmente maligna estudiada, Asimetría, Borde, Color, Diámetro y Evolución. Otras campañas han sido enfocadas a la prevención, sugiriendo protección al momento de estar mucho tiempo a la exposición de los rayos UV provenientes del Sol, sin embargo, aunque estos métodos no dejen de ser efectivos, son ineficientes debido a subjetividad en la práctica.

Los avances en las tecnologías de inteligencia artificial han logrado abarcar un sinnúmero de campos, incluyendo el de la diagnosis de patologías en la medicina, y cada día es más común el uso de esta en el estudio de imágenes, más aun luego de que se desarrollara el concepto de las redes neuronales convolucionales. A diferencia del “ojo clínico”, una red neuronal es entrenada con miles, hasta millones de datos para clasificar información según sea deseado. Esta implementación del aprendizaje de maquina ha ayudado a optimizar el diagnostico de patologías como cáncer de mama, apendicitis y COVID.

Los beneficios a largo plazo de la Inteligencia Artificial en el proceso de diagnóstico de los melanomas promete salvar miles de vidas cada año, por lo cual, el siguiente trabajo de investigación busca desarrollar un sistema basado en redes neuronales convolucionales capaz de identificar melanomas a partir de imágenes.

De esta forma, la presente investigación está compuesta de cinco (5) capítulos, definidos en orden a continuación:

Capítulo I, El Problema, enmarca una de las partes más importantes del trabajo de investigación y se refiere a la descripción general del problema, justificación, objetivos de la investigación, incluyendo objetivos específicos y el alcance de la investigación.

Capítulo II, Marco Teórico, comprende los antecedentes más influyentes sobre la investigación, las bases teóricas que le brindan al investigador el apoyo inicial para el conocimiento del objeto de estudio, las bases legales y los términos básicos que sustentan dicha investigación.

Capítulo III, Marco Metodológico, el cual comprende la descripción de las metodologías utilizadas para dar solución al problema planteado. Aquí se incluyen necesariamente métodos, técnicas y/o procedimientos empleados en el estudio, sustentados con autores.

Capítulo IV, Describe los resultados obtenidos en la realización del proyecto investigativo, especificado por fases y finaliza con las conclusiones y recomendaciones que se han definido en la realización de todo el proceso investigativo.

CAPÍTULO I

EL PROBLEMA

1.1. Planteamiento del problema

Los melanomas son conocidos como el tipo de cáncer de piel más mortífero, aunque conforma tan solo el 1% de los casos, causa la mayoría de las muertes por este tipo de cáncer. La principal causa de melanoma es la exposición a la radiación de luz ultravioleta generalmente proveniente del sol, y, debido a esta exposición excesiva, algunas mutaciones que ocurren al nivel de los melanocitos pueden llevar a la generación de melanomas.

Existen diversos factores que pueden hacer más propensa a una persona a padecer de melanoma de piel, entre los cuales hay circunstancias controlables, como la exposición al sol y el tabaquismo; y otras que salen de las manos del individuo, como la tonalidad de la piel, antecedentes familiares, entre otros.

A pesar de ser uno de los tipos de cáncer de piel más letal, se ha demostrado que la detección temprana del melanoma logra que se pueda sanar con eficacia en un 90% de los casos. Actualmente, el método por defecto para diagnosticar los melanomas es a través del análisis visual de un especialista. Sin embargo, este método toma tiempo y puede llevar a diagnósticos errados debido a la complejidad para obtener una diagnosis certera, ya que se deben analizar una cantidad considerable de parámetros antes de dar un veredicto, el cual, en todos los casos, no será suficiente para declarar como melanoma a la marca observada. Para determinar definitivamente y de forma precisa la lesión, se debe realizar una biopsia del área de piel sospechosa.

La importancia de un temprano diagnóstico para un tratamiento adecuado del melanoma se hace notar por sí mismo, lo que invita a los individuos a estar alerta y vigilantes de las marcas que puedan tener en la piel. Esto es fácil decirlo, pero llevado

a la práctica puede convertirse en un estrés incurable, ya que la necesidad de la opinión médica experta para alertar sobre un posible melanoma solo puede dejar una sensación de impotencia y duda en alguien que intente identificar alguna lesión en la piel por sí solo, esto recalcando que la opinión del médico debe ser corroborada a través de la biopsia.

Un estudio publicado en 2018 en la revista oficial de la Sociedad Europea de Oncología Médica, aborda el tema de la precisión en la detección de melanomas en la piel. Para ello se invitaron a dermatólogos a participar. 58 aceptaron la invitación, de los cuales 17 (29%) indicaron tener menos de dos años de experiencia, 11 (19%) tenían entre tres a cinco años de experiencia y 30 (52%) eran expertos con más de cinco años de experiencia. Se les pidió a los dermatólogos que clasificaran 100 imágenes dermatoscópicas en melanoma maligno o lunar. En promedio los dermatólogos detectaron 86.6% de los melanomas. En un segundo vistazo de las mismas imágenes llegaron a un 88.9%. Tomando en cuenta que para el año 2022, según la Sociedad Americana de Cáncer, se predice un diagnóstico de 99.780 casos solo en Estados Unidos, y teniendo presente la precisión promedio de los dermatólogos, quiere decir que 12.458 casos de melanoma no serán identificados este año.

La dificultad del diagnóstico de un melanoma mediante la observación se debe a la apariencia tan similar de estos con la de un lunar, hay melanomas que a simple vista podrían parecer una marca benigna, como también hay lunares que de solo mirarlo crea alarmas por su similitud con un melanoma. También afecta al diagnóstico el hecho de que todas estas marcas en la piel son diferentes entre sí, y aunque haya factores que sirven para distinguir un melanoma de un lunar, la infinita cantidad de tipos de lesiones hace que resulte casi imposible identificar con total precisión una lesión maligna en la piel. Esta dificultad hace que se planteen nuevas formas de reconocimiento de melanomas en la piel.

Con el auge de la inteligencia artificial han salido a relucir infinidad de aplicaciones para las redes neuronales, entre estas por supuesto hay muchas en el ámbito de la medicina. El reconocimiento y clasificación de imágenes ha sido una

realidad desde hace algunos años atrás, usándose como método de autenticación biométrica, o sirviendo para ordenar imágenes según ciertos parámetros, pero las nuevas técnicas y tecnologías permiten ir más allá.

La existencia de autos autónomos y algoritmos de recomendación en redes sociales cada vez más certeros, hechos realidad gracias a la inteligencia artificial, nos invita a plantear también la utilidad de esta tecnología en el nicho de las lesiones cutáneas. Esto lleva a considerar la necesidad de ampliar los medios e instrumentos de detección de lesiones en la piel para que estas sean tratadas a tiempo utilizando sistemas basados en redes neuronales convolucionales.

1.2. Formulación del problema

¿Cómo solucionar la carencia de métodos para la detección temprana de lesiones en la piel de tipo melanoma?

1.3. Objetivos de la investigación

1.3.1. Objetivo general

Desarrollar un sistema de identificación de melanomas a partir de imágenes basado en redes neuronales convolucionales

1.3.2. Objetivos específicos

- Cuantificar las variables que intervienen en la identificación de melanomas en la piel.
- Identificar los requerimientos funcionales y no funcionales inherentes al sistema de verificación de la presencia de patología en el tejido.
- Desarrollar la arquitectura de la red neuronal más apropiada para el reconocimiento de las lesiones.
- Entrenar a la red neuronal dándole muestras de imágenes mostrando lunares benignos y melanomas cancerígenos.
- Probar a la red neuronal ingresando imágenes ya clasificadas y comparando los resultados dados por la red con el diagnóstico ya establecido.

1.4. Justificación de la investigación

El cuidado de la salud es algo en lo que siempre deberá trabajar la humanidad, y se ha presenciado a través de los años que con los avances en la tecnología también ha aumentado la expectativa de vida de las personas.

No solo se debe este incremento de esperanza de vida a las nuevas prácticas implementadas en la medicina, entre estas y muchas otras cosas que han contribuido hay también que atribuirle gran parte de este mérito al llamado que se ha hecho mundialmente por llevar una vida saludable. Actualmente existe una campaña activa por evitar las prácticas dañinas que en un momento se normalizaron, como lo era fumar. Se invita a las personas a realizar ejercicios, comer de manera sana y realizarse exámenes médicos con frecuencia.

Para que una persona pueda llevar una vida saludable, no solo debe limitarse a cumplir estas recomendaciones que se han esparcido, también debe tener los medios necesarios para identificar los momentos en que su salud está corriendo riesgo para poder actuar a tiempo.

Una de las enfermedades más devastadoras para el ser humano ha sido el cáncer, este muchas veces aparece en sitios donde no es visible y cuando lo detectan puede que esté ya cerca de realizar metástasis. En el caso del cáncer de piel, específicamente con los melanomas, se puede evitar un diagnóstico tardío si se lleva un control adecuado de los lunares o marcas que se posean en la piel.

La importancia y pertinencia de este proyecto, consiste en el desarrollo de un sistema que sea capaz de mejorar el cuidado que cada individuo pueda dar a su salud, y sirva como antecedente para clínicas y hospitales que se puedan servir de su utilidad. El beneficio que traería una tecnología rápida y certera, y además, cómoda para la detección de estas lesiones podría ser aprovechado por millones de personas, para mantenerse sanos, e inclusive salvar vidas como efecto de los diagnósticos hechos a tiempo.

Además, se justifica el presente trabajo por cuanto se encuentra inserta en la línea de investigación: Desarrollo de nuevas tecnologías de la información y comunicación, lo cual hace meritoria su relevancia para esta institución.

1.5. Alcance y Limitaciones

La presente investigación pretende desarrollar un sistema de identificación de melanomas a partir de imágenes basado en redes neuronales convolucionales capaz de transmitir con suficiente certeza si la persona en cuestión debe preocuparse o no sobre alguna marca similar a una lesión maligna que posea en la piel. El estudio estará limitado por factores de tiempo y de hardware, ya que el entrenamiento de redes neuronales demanda una gran capacidad de cómputo, y la cantidad de datos que se le debe dar demora una cantidad considerable de tiempo.

CAPÍTULO II

MARCO TEÓRICO

2.1. Antecedentes de la investigación

Como paso preliminar para la realización de este trabajo, se procedió a la revisión de investigaciones previas relacionadas con el tema de identificación de patologías o distinción de imágenes a través de redes neuronales a nivel nacional e internacional. En este sentido, se muestra el trabajo de Sisco (2018) quien llevo a cabo una investigación en el la Universidad Central de Venezuela para optar por una maestría en ciencias de la computación, titulado **“Reconocimiento facial combinando técnicas de extracción de características con redes neuronales convolucionales”**. El objetivo del trabajo fue evaluar el rendimiento de distintos modelos de reconocimiento facial y también el resultado de la combinación de los mismos. Los modelos estudiados estaban basados en Histogramas de Orientación de Gradientes, Transformaciones de Características Invariantes a la Escala, Histogramas de Patrones Locales Binarios y Redes Neuronales Convolucionales. Para el entrenamiento de la red se utilizó una base de datos de libre acceso con 2800 imágenes llamada FEI (Fundação Educacional Inaciana).

Por otro lado, Gour y Jain (2020) realizaron una investigación en el Instituto Nacional de Tecnologia Maulana Azad, India, titulada **“Stacked Convolutional Neural Network for Diagnosis of COVID-19 Disease from X-ray Images”**. Ellos desarrollaron una red neuronal convolucional llamada CovNet30, obtenida de diferentes sub modelos a partir de la CNN VGG19. Esta red propuesta, combina el poder de discriminación de diferentes sub modelos de CNN de ambas VGG19 y CovNet30, y sería capaz de clasificar imágenes de rayos-x de tórax en COVID-19, Normal y Neumonía. Para el entrenamiento de esta red neuronal utilizaron una

combinación de imágenes de tres data set públicos, denominado COVID19CXr, que incluye 2764 imágenes. Esta red neuronal obtenida consta de 30 capas y es secuencial, donde las capas convolucional con activación ReLU, poolin, normalización de batch y dropout son agregadas repetitivamente. Esta red propuesta tuvo una precisión del 92.74% en la clasificación de las imágenes, en comparación con las redes a partir de las cuales se trabajó, que tenían 89.86% (VGG19) y 87.73% (CovNet30).

En paralelo, Khan, Boodoo-Jahangeer, Dullull, Nathire, Gao, Shina y Nagwanshi (2020) llevaron a cabo una investigación publicada en la revista científica PLOS ONE, titulada “**Multi- class classification of breast cáncer abnormalities using Deep Convolutional Neural Network (CNN)**”, en la cual destacan el problema de la identificación del cáncer de mama en imágenes obtenidas por mamografías, rayos-X o resonancia magnética, cuando esta patología se encuentra en un estado muy prematuro. Al principio esta solo refleja micro calcificaciones, bultos o masas casi imperceptibles, lo que lleva a fasos positivos y falsos negativos. Para solucionar esta problemática, se hizo uso de una red neuronal pre entrenada, llamada ResNet50, aplicando técnicas para evitar el overfitting, el cual ocurre cuando un modelo aprende de manera errónea a identificar el ruido o las fluctuaciones aleatorias que hay en los datos de entrenamiento. Luego, se desarrolló un modelo de CNN mejorado a partir de este. Los datos de entrenamiento fueron tomados de dos bases de datos: CBIS-DDSM y UPMC, ambas de libre acceso. A partir estas dos bases se realizó un dataset a medida. Las imágenes fueron re escaladas a 224 x 224 pixeles y se les aplico “data augmentation”.

La red neuronal pre entrenada ResNet50 fue utilizada para realizar un transfer-learning. Esto ayuda a utilizar rasgos ya aprendidos sobre una tarea, y aplicarlos a otra sin la necesidad de empezar desde cero.

De la misma forma, Álvaro (2020) en su investigación titulada “**Optimización de una red neuronal convolucional para la detección de melanomas en imágenes dermoscópicas**”, presentado en la Universidad Politécnica de Madrid, propone un sistema de clasificación de lesiones de piel en imágenes demoscópicas utilizando redes

neuronales convolucionales. El autor Aborda la problemática realizando una investigación donde se estudian las diferentes arquitecturas de redes neuronales más conocidas, a partir de la cual se selecciona la red llamada “EfficientNet”, propuesta en 2019 por dos miembros de “Google Brain”. Esta red resulta de interés ya que reduce el número de parámetros, reduciendo significativamente los recursos de hardware necesarios para el entrenamiento de la red. Para este entrenamiento se usaron los datos del ISIC Challenge 2019, los cuales se introdujeron en la red elegida. A partir de los resultados obtenidos, se aplicaron técnicas de data augmentation sobre los datos de entrenamiento y variaciones sobre los hiperparámetros de la red para estudiar el efecto de dichas operaciones en los resultados. Luego de realizar las pruebas, se llegó a la conclusión de que el mejor modelo se obtenía de aplicar las técnicas de data augmentation y otras técnicas como “Dropout” y “Class balanced loss”. Esta técnica anteriormente mencionada, se utiliza debido a que el trabajo abarca los ocho tipos de lesiones en la piel, y la base de datos utilizada tiene una proporción de datos desproporcionada de cada tipo de lesión, por lo tanto, para evitar que esta diferencia en la cantidad de datos afecte en el entrenamiento, el “Class Balanced Loss aplica un multiplicador al cálculo de la función de pérdidas distinto para cada tipo de lesión, que depende del número de imágenes que se tengan de la misma.

Para finalizar, Yalcinkaya y Erbas (2021) del departamento de ingeniería eléctrica y electrónica de la Universidad de Kirkkale, Turquía, escribieron un artículo publicado en la revista Tech Science Press, titulado “**Image Masking and Enhancement System for Melanoma Early Stage Detection**”, donde proponen una red neuronal convolucional basada en una arquitectura de dos pasos para realizar el diagnóstico de melanomas en la piel utilizando una CNN. El primer paso y el pilar de la investigación, sería procesar las imágenes de entrada con un algoritmo de mejora, con la intención de aislar la lesión de la piel, y que la red neuronal sea más acertada en el proceso de aprendizaje. Para ello, diseñaron un sistema basado en Fuzzy Logic con el fin de tener el contorno de la lesión bien definido y de esta manera que la piel de alrededor de la misma no influya en la clasificación de las imágenes. Al aplicar este

procesamiento de imágenes de dos pasos, logaron una mejoría en las CNN probadas, las cuales fueron AlexNet, GoogLeNet, ResNet, VGG16, VGG19, Inception, ShuffleNey y Xception.

2.2. Bases teóricas

Según Arias, “Las bases teóricas implican un desarrollo amplio de los conceptos y proposiciones que conforman el punto de vista o enfoque adoptado, para sustentar o explicar el problema planteado” (2006).

2.2.1. Sistema

Un sistema puede definirse como un conjunto de partes o una serie de elementos que integran una actividad, un procedimiento o un plan de procesamiento, el cual busca una meta o metas comunes, mediante la manipulación de datos, energía o materia, en una referencia de tiempo, para proporcionar información, energía o materia (Mudrick y Ross 1982).

Un sistema tiene entradas, que luego de un proceso generan salidas. Para las ciencias de la computación y específicamente, en el desarrollo de software, estas salidas son generadas a partir de datos que son introducidos por el usuario. Este dato ingresado puede ser interpretado como cualquier información que la computadora pueda comprender, y que el sistema creado sea capaz de procesar. Este proceso debe estar orientado a producir una salida que brinde una respuesta clara y en concordancia con el objetivo del sistema.

2.2.2. Melanoma

“El melanoma es una neoplasia maligna de melanocitos, células que producen pigmento originadas de la cresta neural y que migran a la piel, las meninges, las membranas mucosas, la zona superior del esófago y los ojos. En cada uno de estos órganos dichas células tienen la capacidad de transformarse en otras cancerosas, pero la mayor parte se origina en la piel.” (Curti B.D. et ál., 2018).

Entre las causas principales de las lesiones en la piel, se encuentra la exposición a la radiación UV que proviene del sol. De los diferentes tipos de lesiones cutáneas que existen, el melanoma tiene la tasa más alta de malignidad, lo que lleva a un alto índice de mortalidad.

La lesión cutánea más común es el Nevus, comúnmente conocido como “lunar”. Se trata de una lesión potencialmente cancerosa, pero se considera benigna debido a su bajo índice de malignidad.

2.2.3. Aprendizaje de Máquina

El aprendizaje de máquina es la ciencia (y arte) de programar computadoras de tal forma que sean capaces de aprender a partir de datos. Tom Mitchell establece que: “Se dice que un programa aprende de la experiencia E con respecto a alguna tarea T y una medida de desempeño D, si su desempeño en T, medida como D mejora con experiencia E” (1997). Se puede simplificar esta definición de esta manera: es el campo de estudio que le da la habilidad a las computadoras de aprender, sin necesidad de que estas sean explícitamente programadas.

Hay muchos tipos de aprendizaje de máquina, y estos se clasifican según los siguientes criterios:

- Si el modelo es entrenado o no con supervisión humana (supervisado, no supervisado, semi-supervisado y aprendizaje reforzado)
- Si puede aprender de manera incremental mientras se utiliza (aprendizaje en línea vs aprendizaje por lotes)
- Si puede funcionar simplemente comparando datos nuevos, con datos conocidos, o trabaja detectando patrones con la data de entrenamiento y construye un modelo predictivo (aprendizaje basado en instancias o basado en modelos)

Estos criterios no son exclusivos, los mismos se pueden combinar entre sí. Gerón A. (2019) define los tipos de aprendizaje de máquina de la siguiente manera:

- **Aprendizaje Supervisado:** en el aprendizaje supervisado, el conjunto de entrenamiento que se da de entrada al algoritmo incluye las soluciones deseadas

en forma de etiquetas asociadas. Una tarea común encomendada a este tipo de aprendizaje es la de clasificación.

- **Aprendizaje no supervisado:** estos modelos no cuentan con las referencias dadas a un algoritmo supervisado, aprenden “sin un profesor”. El objetivo de los mismos es descifrar patrones que permitan organizar la data.
- **Aprendizaje semi-supervisado:** estos algoritmos reciben este nombre debido a su capacidad de lidiar con data clasificada y no clasificada.
- **Aprendizaje por lotes (batch learning):** en este tipo de algoritmos, el sistema es incapaz de aprender incrementalmente. Es necesario que este sea entrenado utilizando toda la data disponible, esto requiere tiempo y recursos computacionales considerables, y se realiza generalmente de manera local (offline).
- **Aprendizaje en línea (online learning):** en este tipo de aprendizaje, el sistema se entrena incrementalmente, ingresando data secuencialmente, ya sea de manera individual o en pequeños grupos, llamados “mini lotes”. El aprendizaje en línea es excelente para sistemas que reciben data continuamente.
- **Aprendizaje basado en instancias (Instance-based learning):** es la manera más trivial de aprendizaje, se toma como referencia un modelo exacto de data y se usa para la “comparación” con el dato que se ingrese. De esta manera, se establece un valor de similitud y si la instancia estudiada lo cumple, es clasificado según la referencia tomada.
- **Aprendizaje basado en modelos (model-based learning):** esta manera de generalizar a partir de un conjunto de ejemplos consiste en construir un modelo de estos y usar dicho modelo para realizar predicciones.

2.2.4. Redes Neuronales Artificiales

Las redes neuronales artificiales son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica,

las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico. (Kohonen 88c).

En el desafío de programar una computadora para que sea capaz de “pensar”, se tomó como referencia la arquitectura del cerebro, y así se llegó a las redes neuronales artificiales. Estas no son más que un modelo de aprendizaje de máquina inspirado por las redes de las neuronas biológicas encontradas en el cerebro.

Históricamente, el concepto de plantear un modelo de una neurona se estableció por primera vez en 1943 por Warren McCulloch y Walter Pitts basándose en circuitos lógicos. Luego, en 1958, Frank Rosenblatt creó el primer modelo matemático de una neurona y lo llamó “perceptrón”. Este es una unidad básica matemática que se comporta como una neurona biológica. El resultado de esta unidad se obtiene mediante la aplicación de una función de activación sobre el sumatorio de una cantidad “n” de entradas ponderadas.

2.2.5. Redes Neuronales Convolucionales

Las redes neuronales convolucionales son un tipo de RNA usadas para el procesamiento de imágenes. Se basan en operaciones de convolución. La convolución consiste en filtrar una imagen computacionalmente utilizando una máscara, donde los píxeles de salida resultan ser una combinación lineal de los píxeles de entrada. Esta entrada es, en la mayoría de los casos, una imagen de dimensiones $W \times H \times D$, estas siendo respectivamente: ancho, alto y número de canales. Estas convoluciones se emplean para reducir la carga computacional del sistema. (Gerón A., 2019)

2.2.6. Arquitectura de Redes Neuronales Convolucionales

Las Redes Neuronales Convolucionales se forman empleando tres tipos de capas principalmente: capas convolucionales, capas de pooling y capas totalmente conectadas (fully connected).

- **Capa Convolutiva:** Este es el eje central de una red convolutiva. Realiza la mayor parte del trabajo. Estas capas de convolución, tienen K filtros denominados “kernels” de dimensión $(W \times H \times D)$, elegida por el diseñador de

la red. La función de cada filtro es generar, mediante convolución, un mapa de rasgos o características de tamaño $(W+1) \times (H+1) \times P$, donde P es el número de filtros que se utilizarán. Este mapa de rasgos viene dado en forma de un conjunto de matrices de salida, obtenidas a partir de los filtros aplicados a la imagen. Cada filtro o neurona sirve para extraer el mismo rasgo en cualquier parte de la imagen, tomando en cuenta el hecho de que un mismo rasgo se puede obtener en diversos lugares de esta. (Pérez C., 2019).

Las capas convolucionales operan superponiendo el filtro y la imagen de entrada, se calcula la convolución entre los elementos de la imagen y del filtro, y el resultado se va almacenando en la matriz de activación. Consiste en tomar grupos de píxeles cercanos de la imagen de entrada e ir realizando un producto escalar de los valores de esta matriz de píxeles con la matriz del kernel. Se debe tomar en cuenta que la imagen antes de ser procesada debe ser normalizada. La normalización de la imagen se efectúa considerando los valores RGB que puede tomar un píxel. Cada uno de estos puede tomar valores que van de 0 a 255, por lo que se transforma cada valor de píxeles de la imagen a su valor dividido entre 255, y así se obtiene un valor que siempre está entre cero y uno.

Para cada una de estas capas de convolución también se deben tomar en cuenta otros dos parámetros además del tamaño del filtro a utilizar, la zancada (stride) y el relleno (padding). El número de píxeles que se ira desplazando el filtro al realizar la convolución viene dado por el stride; y el padding añade píxeles auxiliares para obtener una matriz del tamaño deseado al momento de realizar la convolución.

Luego de haber recorrido toda la imagen mediante este proceso, se obtiene la matriz de activación.

- **Capa Pooling:** En esta capa se realiza un muestreo de los resultados obtenidos en las capas de convolución mediante la operación max pooling o average

pooling, esto se aplica en regiones contiguas de la matriz de tamaño $P \times P$. Como lo indican sus nombres en inglés, max pooling se encarga de obtener el mayor valor de la región, y average pooling retorna el valor medio de la región. La matriz luego de ser sometida a la capa de pooling, reducen sus dimensiones de $W \times H \times D$ a $W/P \times H/P \times D$. Esto disminuye el número de parámetros y tiempo de computación. (Pérez C., 2019).

- **Capa Fully Connected:** En una capa totalmente conectada (fully connected), las neuronas tienen conexiones completas con las activaciones de la capa precedente. Las dimensiones de la capa de salida dependerán de las dimensiones de cada una de las capas de entrada. Estas capas fully connected son aplicadas al final, y luego de esta solo sigue la capa clasificadora de las imágenes de entrada. (Pérez C., 2019).

2.2.7. Teoría de la computabilidad

Altamirano L. establece que: “La teoría de la computabilidad se centra en el estudio de la complejidad de los objetos matemáticos en función de la dificultad de dar un algoritmo para calcularlos” (2021). Esta se originó en la década de los años 30 con los trabajos de los lógicos Church, Gödel, Kleene, Post y Turing.

2.3. Bases legales

Según Villafranca D. “Las bases legales no son más que las leyes que sustentan de forma legal el desarrollo del proyecto” explica que las bases legales “son leyes, reglamentos y normas necesarias en algunas investigaciones cuyo tema así lo amerite”. (2002)

Las bases legales de esta investigación se encuentran representadas, en primer lugar, en la **Constitución de la República Bolivariana de Venezuela (1999)**.

Artículo 98. La creación cultural es libre. Esta libertad comprende el derecho a la inversión, producción y divulgación de la obra creativa, científica, tecnológica y humanística, incluyendo la protección legal de los derechos del autor o de la autora sobre sus obras. El Estado reconocerá y protegerá la propiedad intelectual sobre las

obras científicas, literarias y artísticas, invenciones, innovaciones, denominaciones, patentes, marcas y lemas de acuerdo con las condiciones y excepciones que establezcan la ley y los tratados internacionales suscritos y ratificados por la República en esta materia.

Artículo 110. El Estado reconocerá el interés público de la ciencia, la tecnología, el conocimiento, la innovación y sus aplicaciones y los servicios de información necesarios por ser instrumentos fundamentales para el desarrollo económico, social y político del país, así como para la seguridad y soberanía nacional. Para el fomento y desarrollo de esas actividades, el Estado destinará recursos suficientes y creará el sistema nacional de ciencia y tecnología de acuerdo con la ley. El sector privado deberá aportar recursos para los mismos. El Estado garantizará el cumplimiento de los principios éticos y legales que deben regir las actividades de investigación científica, humanística y tecnológica. La ley determinará los modos y medios para dar cumplimiento a esta garantía.

Ley Orgánica de Ciencia, Tecnología e Innovación (2014)

Artículo 2. Las actividades científicas, tecnológicas, de innovación y sus aplicaciones son de interés público para el ejercicio de la soberanía nacional en todos los ámbitos de la sociedad y la cultura.

Artículo 21. La autoridad nacional con competencia en materia de ciencia, tecnología, innovación y sus aplicaciones creará mecanismos de apoyo, promoción y difusión de invenciones e innovaciones populares, que generen bienestar a la población o logren un impacto económico o social en la Nación.

2.4. Definición de términos básicos

Melanocito: El instituto nacional del cáncer de estados unidos los define como una “Célula de la piel y los ojos que produce y contiene un pigmento llamado melanina”. Su principal función es la de bloquear los rayos ultravioleta solares, evitando que dañen el ADN de las células de estas regiones tan expuestas a la luz.

Python: Duran F. define Python como:

“Un lenguaje de programación interpretado cuya filosofía hace hincapié en una sintaxis que favorezca un código legible. Se trata de un lenguaje de programación multiparadigma, ya que soporta orientación a objetos, programación imperativa y, en menor medida, programación funcional. Es un lenguaje interpretado, usa tipado dinámico y es multiplataforma, lo que significa que cualquier sistema es compatible con el lenguaje siempre y cuando exista un intérprete programado para él.” (s/f, p. 01).

Scikit-Learn: Biblioteca de aprendizaje automático para Python. Incluye diversos algoritmos de clasificación, regresión y análisis de grupos entre los que destacan máquinas de vectores de soporte, random forests, Gradient boosting, K-means y DBSCAN. (Pedragosa, F. et ál., 2011).

Keras: Utrera, J. (s/f) señala que Keras: “Es un framework de alto nivel para el aprendizaje, escrito en Python y capaz de correr sobre los frameworks TensorFlow, CNTK, o Theano. Fue desarrollado con el objeto de facilitar un proceso de experimentación rápida”. Sus fuertes se centran en ser amigable para el usuario, modular y extensible.

TensorFlow: Dean, J. (2015), establece que TensorFlow es una biblioteca de código abierto para aprendizaje automático a través de un rango de tareas, y desarrollado por Google para satisfacer sus necesidades de sistemas capaces de construir y entrenar redes neuronales para detectar y descifrar patrones y correlaciones, análogos al aprendizaje y razonamiento usados por los humanos.

Convolución: es un operador matemático que transforma dos funciones f y g en una tercera función que en cierto sentido representa la magnitud en la que se superponen f y una versión trasladada e invertida de g .

Overfitting: El overfitting o sobreajuste es el efecto de sobreentrenar un algoritmo de aprendizaje con unos ciertos datos para los que se conoce el resultado deseado. El algoritmo puede quedar ajustado a unas características muy específicas de los datos de entrenamiento que no tienen relación causal con la función objetivo.

Underfitting: Se puede traducir al español como “infrajuste”, se produce cuando el modelo no es capaz de identificar patrones en los datos de entrenamiento

ReLU: La función de activación lineal rectificadora o ReLU para abreviar es una función lineal por partes que generará la entrada directamente si es positiva; de lo contrario, generará cero (Brownlee, J., 2019). Se ha convertido en la función de activación predeterminada para muchos tipos de redes neuronales porque un modelo que la usa es más fácil de entrenar y, a menudo, logra un mejor rendimiento.

SoftMax: la función softmax, o función exponencial normalizada, es una generalización de la Función logística. Se emplea para "comprimir" un vector K-dimensional, z , de valores reales arbitrarios en un vector K-dimensional, $\sigma(z)$, de valores reales en el rango $[0, 1]$. (Bishop, C., 2006).

CAPÍTULO III

MARCO METODOLÓGICO

3.1. Tipo de investigación

Para Rojas (2003), Es necesario definir o ubicar tipos de investigación o esquemas por seguir adecuados -según la naturaleza del problema por investigar-, para ello existen diferentes clasificaciones basadas en distintos criterios.

Teniendo en cuenta que la presente investigación tiene como objetivo principal el desarrollo de un software que prediga candidatos a fármaco, se determinó que el tipo de investigación del presente trabajo es “Proyecto Especial”, el cual esta descrito según la Mijares H, Garcia E (2007), como Creaciones tangibles, susceptibles de ser utilizadas como soluciones a problemas demostrados, o que respondan a necesidades e intereses de tipo cultural. Se incluyen en esta categoría los trabajos de elaboración de libros de textos y de materiales de apoyo educativo, el desarrollo de software y hardware, prototipos y de productos tecnológicos en general.

3.2. Diseño de la investigación

Para Arias (2006), en este punto se especifica el tipo de investigación según el diseño o estrategia adoptada para responder al problema planteado. Según el diseño, la investigación puede ser documental, de campo o experimental. Así mismo, cada tipo se puede realizar a nivel exploratorio, descriptivo o explicativo.

De igual manera Arias describe la investigación documental como “un proceso basado en la búsqueda, recuperación, análisis, crítica e interpretación de datos secundarios, es decir, los obtenidos y registrados por otros investigadores en fuentes documentales: impresos, audiovisuales o electrónicas.” (2006, p. 27).

Tomando estos conceptos en cuenta, se definió que la presente investigación tiende a ser documental, debido a que los datos requeridos serán recolectados de una base de datos de acceso público.

3.3. Nivel de la investigación

Según Arias: “El nivel de investigación se refiere al grado de profundidad con que se aborda un fenómeno u objeto de estudio.” (2006, p. 23). Agregado a esto, para Arias:

La investigación descriptiva consiste en la caracterización de un hecho, fenómeno, individuo o grupo, con el fin de establecer su estructura o comportamiento. Los resultados de este tipo de investigación se ubican en un nivel intermedio en cuanto a la profundidad de los conocimientos se refiere. (2006, p. 24).

La presente investigación es de tipo descriptivo con enfoque mixto, ya que comprende la descripción, registro y análisis de todos los parámetros que son necesarios para el desarrollo de un sistema basado en redes neuronales convolucionales que sea capaz de clasificar imágenes de posibles lesiones en la piel.

3.4. Población y muestra

Tomando en cuenta la definición dada por Arias, quien señala que:

La población, o en términos más precisos población objetivo, es un conjunto finito o infinito de elementos con características comunes para los cuales serán extensivas las conclusiones de la investigación. Ésta queda delimitada por el problema y por los objetivos del estudio (2006, p. 81).

Y de esta misma manera, establece que: “La muestra es un subconjunto representativo y finito que se extrae de la población accesible” (Arias, 2006, p. 83).

Para esta investigación se utilizó una muestra intencionada, debido a que solo individuos debidamente preparados pueden tener un criterio fundamentado para brindar información fidedigna sobre la problemática estudiada. De esta manera, se tomó como población a las herramientas para diagnóstico e identificación de melanomas, y la muestra está conformada por las herramientas para diagnóstico e identificación de melanomas basadas en redes neuronales.

3.5. Técnicas e instrumentos de recolección de datos

En cuanto a las técnicas e instrumentos de recolección de datos, Arias define que: “Se entenderá por técnica de investigación, el procedimiento o forma particular de obtener datos o información” (2006, p. 67). De esta misma manera, Arias establece que: “Un instrumento de recolección de datos es cualquier recurso, dispositivo o formato (en papel o digital), que se utiliza para obtener, registrar o almacenar información” (2006, p. 68).

El primer lugar, se utilizó la recopilación documental la cual Torrealba & Rodríguez (2009) definen como “un instrumento o técnica de investigación general cuya finalidad es obtener datos e información a partir de fuentes documentales con el fin de ser utilizados dentro de los límites de una investigación en concreto”. Lo cual fue la revisión bibliográfica de diversas fuentes cuya información fue necesaria y se aplicó en la investigación, en este caso se centró en diseño y desarrollo de redes neuronales convolucionales, así como también en el área metodológica de ingeniería del software.

También se dispuso de otra técnica para obtener los datos, la entrevista, la cual está definida por Arias, como: “más que un simple interrogatorio, es una técnica basada en un diálogo o conversación “cara a cara”, entre el entrevistador y el entrevistado acerca de un tema previamente determinado, de tal manera que el entrevistador pueda obtener la información requerida” (2006, p. 73).

Al contar con entrevistados que poseen conocimiento del tema y están empapados de la información necesaria, se obtiene una gran herramienta de recolección de datos debido a la capacidad que se tiene de dar base a la investigación a partir de sus respuestas. La entrevista se aplicó de una manera no estructurada, a través de la cual se obtuvieron requerimientos que tanto el sistema como la red neuronal (mayormente en su fase de entrenamiento) requerían para cumplir a cabalidad el objetivo.

3.6. Fases metodológicas

El presente trabajo de investigación se llevará a cabo siguiendo, en orden lógico, una secuencia de pasos, conformados por:

Fase I: Cuantificación de las variables que intervienen en la identificación de melanomas en la piel.

En esta fase, se recogerá la información obtenida proveniente por parte de los médicos seleccionados como muestra, haciendo uso de los instrumentos de recolección de datos documentados, donde se resalta la aplicación de entrevistas no estructuradas, permitiendo así conocer la visión de quienes poseen mayor experiencia en el diagnóstico de melanomas y los factores que dificultan el mismo.

Fase II: Determinación de los requerimientos funcionales y no funcionales inherentes al sistema de verificación de la presencia de patología en el tejido.

Habiendo recogido la información pertinente para el desarrollo, se hará uso de esta para establecer en esta fase los requerimientos funcionales y no funcionales del sistema de reconocimiento de melanomas basado en redes neuronales convolucionales.

Fase III: Desarrollo de la arquitectura de red neuronal más apropiada para el reconocimiento de las lesiones.

Habiendo concluido con el establecimiento de los requerimientos funcionales y no funcionales, se procederá con el desarrollo del sistema. La construcción del sistema se materializará mediante la implementación de la metodología XP, cumpliendo con las características fundamentales de la metodología como lo son el desarrollo iterativo e incremental, las pruebas unitarias continuas, la corrección de todos los errores, la refactorización del código y la simplicidad el mismo. A pesar de que esta es una metodología recomendada para formar parejas de desarrolladores, el enfoque de la misma resulta útil así se esté trabajando en el desarrollo de manera individual. Las fases de la metodología XP son:

- **Fase de planeación:** El primer paso de cualquier proyecto que siga la metodología XP es definir las historias de usuario con el cliente. Las historias de usuario tienen la misma finalidad que los casos de uso, pero con algunas diferencias: Constan de 3 ó 4 líneas escritas por el cliente en un lenguaje no técnico sin hacer mucho hincapié en los detalles; no se debe hablar ni de posibles algoritmos para su implementación ni de diseños de base de datos adecuados, etc. Son usadas para estimar tiempos de desarrollo de la parte de la aplicación que describen. También se utilizan en la fase de pruebas, para verificar si el programa cumple con lo que especifica la historia de usuario. Cuando llega la hora de implementar una historia de usuario, el cliente y los desarrolladores se reúnen para concretar y detallar lo que tiene que hacer dicha historia.
- **Fase de diseño:** El proceso de diseño debe procurar diseños simples y sencillos para facilitar el desarrollo. Se recomienda elaborar un glosario de términos y la correcta especificación de métodos y clases para facilitar posteriores modificaciones, ampliaciones o reutilización del código.
- **Fase de codificación:** En esta fase los desarrolladores deben diseñar las pruebas de unidad que ejercitarán cada historia de usuario.
- **Fase de pruebas:** Las pruebas de unidad deben implementarse con un marco de trabajo que permita automatizarlas, con la finalidad de realizar pruebas de integración y validación diarias, esto proporcionará al equipo un indicador del progreso y revelarán a tiempo si existe alguna falla en el sistema.

Fase IV: Entrenamiento de la red neuronal dándole muestras de imágenes mostrando lunares benignos y melanomas cancerígenos.

Esta fase es fundamental para el correcto funcionamiento del sistema. El entrenamiento de la red consiste en alimentar a la misma con datos ya clasificados, de esta manera los algoritmos desarrollados encuentran patrones en

las imágenes, los cuales serán utilizados para la identificación de melanomas en la imagen. El entrenamiento de la red, hecho de manera adecuada, establecerá el éxito o el fracaso del sistema.

Fase V: Realización de pruebas a la red neuronal ingresando imágenes ya clasificadas y comparando los resultados dados por la red con el diagnostico ya establecido

Para finalizar, en esta fase, atendiendo los lineamientos de la metodología XP, se realizarán distintos tipos de pruebas al sistema. Estas pruebas permitirán determinar si el software tiene un funcionamiento adecuado y, además, evalúa si los requisitos preestablecidos fueron cumplidos. En el caso de haber existido la condición de error, se procederá a corregir las fallas.

CAPÍTULO IV

RESULTADOS

Para el desarrollo de sistemas es fundamental seguir especificaciones que permitan a los desarrolladores tener una estructura que asegure que todas las etapas de construcción del sistema, desde la fase inicial de recolección de los requerimientos hasta las pruebas finales del sistema, logrando así que estas sean no solo coherentes si no también tener un mayor control de los recursos destinados para el trabajo de grado.

Esto se logra, utilizando ciertas metodologías, las cuales nos permiten establecer un entorno que facilite y aumente la productividad del equipo que realiza el proyecto, al mismo tiempo impulsa la creación de mejores productos, ya que se definen parámetros para cada tipo de proyecto. Teniendo esto en cuenta, se realizó un estudio de las diversas metodologías, para de esta manera obtener la más factible para desarrollar una aplicación con estas características, concluyendo que la más oportuna es la metodología XP, ya que es una metodología ágil y flexible que se centra en ciertas variables y prácticas que fortalecen la productividad a la hora del desarrollo de softwares, por lo cual, se logró dividir el desarrollo de la aplicación en 5 fases tal como dicta la metodología, siendo estas: diagnóstico, determinación, diseño, desarrollo y pruebas, así alcanzar el desarrollo óptimo de la aplicación.

4.1. Fase I: Cuantificación de las variables que intervienen en la identificación de melanomas en la piel.

Mediante la elaboración de un guion para la entrevista, así como la aplicación de los métodos y técnicas mencionados con anterioridad, se logró obtener una visión general de cómo se maneja la identificación y diagnóstico de melanomas en el país, y como es la utilización de softwares de predicción en este campo, aunado a esto, con esta información se extrajeron todos los datos necesarios para definir los requisitos funcionales y no funcionales del sistema.

4.1.1 Actividad I: Investigación de sistemas con similitudes a la plataforma que se planteó desarrollar.

Se investigaron diferentes modelos de redes neuronales con características similares, para de esta manera, entender mejor el funcionamiento de las mismas y tener una referencia de los mejores optimizadores para una red con este tipo de propósito.

Durante esta investigación se encontró la plataforma Kaggle, la misma es una página online donde se realizan diversas competencias informáticas, entre las cuales hay varias de clasificación de datos utilizando redes neuronales.

4.1.2 Actividad II: Elaboración del guion para la entrevista y aplicación.

En esta actividad se elaboró el guion para la entrevista según la investigación previamente realizada, esto con la finalidad de poder analizar las mejoras de características previamente planteadas y poder ajustarlo más a las necesidades de los usuarios, además también poder comprender con mayor claridad el proceso que implica el diagnóstico de un melanoma en la piel, y que papel cumple la inspección visual de la piel durante la identificación de posibles lesiones malignas. En cuanto a los resultados de estas entrevistas, se obtuvo:

1. ¿Cuáles son las características que identifican un melanoma en la piel?

Tabla 1. Respuesta pregunta n° 1 entrevista.

Informante Clave N°	Respuestas
1	Aparición de un lunar nuevo en la piel o un lunar existente que haya cambiado en tamaño, forma o color. Aplicar la regla de ABCDE. A de asimetría: las dos mitades no don iguales. B de borde: bordes irregulares o desiguales. C de color: color no uniforme. Colores negro, marrón, rosado o blanco no homogéneos. D de diámetro. >de 6 mm E de evolución en el

	<p>tiempo. Cambios en la forma, color, aparición de prurito o dolor.</p>
2	<p>El paciente observa la presencia de manchas o lunares nuevos, de color oscuro generalmente negros o rojos que pueden ir creciendo con el tiempo , se pueden en ocasiones ulcerar y hasta sangrar, que podrían evolucionar a sobre elevarse en la piel y con estos síntomas acuden a la evaluación médica especializada con dermatólogo.</p> <p>En ocasiones además de la lesión pigmentada en piel puede asociarse otros síntomas como dolor abdominal, molestias gastrointestinales, óseas y otras, lo cual lleva a evaluar al pacientes de forma integral con demás especialidades médicas pertinentes</p>
3	<p>La característica más importante para el melanoma es algún lunar nuevo en la piel o uno existente que haya cambiado en tamaño, forma o color.</p> <p>Otra característica importante es algún lunar que luzca distinto a los otros en su piel (conocido como el signo del patito feo).</p>
4	<p>Una lesión de aspecto heterogéneo (coloración irregular) , de bordes irregulares mal definidos, que presente un crecimiento rápido y un tamaño mayor de 6mm.</p>
5	<p>Para identificar un melanoma mediante lunares inusuales, se debe tener en cuenta cinco aspectos fundamentales: si este presenta una asimetría notable, un borde irregular, cambios extraños de color, un tamaño alrededor de 6mm y si este evoluciona ocasionando otros síntomas como picazón o sangrado.</p>

Fuente: Aure (2022).

Breve análisis: con esta pregunta se evidencia que los melanomas tienden a tener características diferentes al resto de las marcas en la piel, pudiendo así ser de alguna manera clasificadas en lunares o posibles lesiones malignas. Un factor a tomar en cuenta es la aparición de síntomas no observables en los individuos, cuestión que no se puede tomar en cuenta la momento de clasificar lesiones partiendo sólo de imágenes.

2. ¿Con qué certeza se puede afirmar a partir de la observación que una lesión en la piel es un melanoma?

Tabla 2. Respuesta pregunta n° 2 entrevista.

Informante Clave N°	Respuestas
1	<p>Si un lunar cumple con cualquiera de los criterios del ABCDE, debe ser evaluado a la brevedad por un dermatólogo. No todos los melanomas pueden ser detectados mediante la regla del ABCDE.</p> <p>El examen de piel habitual es de gran importancia para diagnosticar en etapas tempranas el Melanoma.</p>
2	<p>Cuando el paciente es evaluado por un experto dermatólogo se realiza la observación clínica minuciosa aplicando la Regla de ABCDE, este acrónimo describe :</p> <p>A-asimetría B-borde C-color D-diámetro E-evolución</p>

	<p>Con uno o más de estos criterios se debe tomar conducta médica.</p> <p>Seguidamente en la evaluación clínica de una lesión pigmentada se realiza la dermatoscopia que es el uso de un equipo llamado dermatoscopio que permite una vez que se incide el equipo sobre la lesión observar magnificando la lesión y aplicando luz se aplica los patrones dermatoscopicos dando así un diagnóstico clínico definitivo con una validez 99%</p>
3	<p>La regla ABCDE es un método para identificar las señales habituales del melanoma. Debemos estar alerta y notificar a su especialidad en este caso el dermatólogo si observa lunares que tengan cualquier similitud con el ABCD</p>
4	<p>Para sospechar de una lesión tipo melanoma nos apoyamos en las probabilidades que tiene un paciente de padecer esta entidad, antecedentes familiares, lesiones previas confirmadas, así como de las características clínicas de la lesión mencionadas en la pregunta uno. No podemos afirmar que una lesión es de determinada estirpe hasta tener el diagnóstico histopatológico, sería imprudente hacerlo, en base a los hallazgos clínicos sólo podemos establecer un diagnóstico probable.</p>
5	<p>Primero que todo, observando las cinco características explicadas anteriormente. Asimismo, aspectos como conocer los antecedentes familiares del paciente respecto al cáncer de piel como si ha sufrido algún tipo de lesión en tiempos pasados, puede asentar la idea de que el paciente padezca la dolencia.</p>

Fuente: Aure (2022).

Breve análisis: con estas respuestas, se pudieron identificar las características más comunes que señalan la presencia de un melanoma en la piel.

Sin embargo, también se detalló que no todos los melanomas pueden ser clasificados a partir de estas características. Esto indica que, si bien existen patrones reconocibles que caracterizan a las lesiones malignas, no se han descubierto con total exactitud todos los factores que puedan dar una total fidelidad de que una lesión es un melanoma.

3. ¿Existe alguna razón por la cual los individuos no se percaten de que poseen esta dolencia?

Tabla 3. Respuesta pregunta n° 3 entrevista.

Informante Clave N°	Respuestas
1	<p>Falta de conocimiento</p> <p>Miedo de asistir a la consulta y por lo tanto no ser examinado en el momento oportuno.</p> <p>No tener acceso a la consulta dermatológica</p> <p>Las ocupaciones diarias y el exceso de trabajo del paciente que retardan o hace que se posponga la cita a la consulta dermatológica.</p>
2	<p>La razón es la poca educación de la población en cuanto a examinar su piel y uñas, que se desconozca que la piel es un reflejo del medio interno del cuerpo humano que se debe vigilar cuidar y evaluar.</p> <p>Fomentar educación en salud disminuye el riesgo muerte en la población.</p>
3	<p>La mayoría de los pacientes no sienten nada al momento de tener esa lesión</p>
4	<p>Con frecuencia la gente no acude al médico hasta el último momento, muchas veces por miedo al diagnóstico, otras</p>

	simplemente por ignorancia. Estas lesiones también pueden ubicarse en sitios donde el paciente no logra verlas.
5	Sí, puesto que también existen los melanomas conocidos como “ocultos”. Estos aparecen en lugares donde la mayoría de la gente no considera revisar (debajo de la uña, en la boca, vías urinarias...) No obstante, aunque el melanoma se manifieste con lunares, muchos no acuden al médico porque no se han dado cuenta, por ignorancia en el tema o debido a que temen al resultado del diagnóstico.

Fuente: Aure (2022).

Breve análisis: con estas respuestas se evidenció que el principal factor que influye en el desconocimiento de los individuos al padecer esta lesión, es la falta de examinación y la inconciencia de su padecimiento al momento de poseerla. Entre las respuestas también se mencionó el hecho de no tener acceso a una consulta dermatológica, cuestión que también busca solucionar el desarrollo de este sistema.

4. ¿Qué medidas se pueden tomar para emitir un diagnóstico temprano ante un melanoma?

Tabla 4. Respuesta pregunta n° 4 entrevista.

Informante Clave N°	Respuestas
1	Auto examen de piel mensual. Solo necesitas tus ojos un espejo de mano para ver las áreas difíciles y un sitio con buena luz. Acudir a la consulta dermatológica por lo menos dos veces al año.
2	-Auto examen de la piel y uñas del paciente.

	<p>-Al presentar cualquier lesión en piel acudir al Especialista Dermatólogo.</p> <p>-Los médicos que evidencien cualquier lesión en piel y uñas de sus pacientes, refieran a su paciente a consulta con Especialista Dermatólogo.</p> <p>- No menospreciar cualquier lesión o cambio en la piel y uñas. Finalmente regla de oro consulta a Especialista Dermatólogo siempre que tengas problemas dudas o cualquier síntoma en piel pelos y uñas.</p>
3	<p>Para llevar a cabo las medidas es necesario concientizar a los pacientes de que el chequeo de nuestra piel debe ser parte fundamental en la consultas tanto de salud pública como privadas. Siendo el órgano más amplio que tenemos y el estar más expuesto pues a veces nos descuidamos dos medidas esenciales en la prevención del melanoma: deben ser la autoexploración y protección de los rayos ultravioleta.</p> <p>La autoexploración se debe realizar una vez al mes; en ella debe inspeccionarse toda la extensión corporal con la ayuda de lupas, sin olvidar el fondo de las uñas, los pliegues entre los dedos y el cuero cabelludo. Cada lunar o mancha extraña debe someterse a las regla del ABCDE, en caso de duda, siempre consultar a un especialista en dermatología. Y siempre recordar que un diagnóstico precoz del melanoma puede salvar la vida.</p>
4	<p>Ante una lesión nueva de características distintas a la de un lunar "normal" acudir al médico especialista. Toma de biopsia y diagnóstico histopatológico.</p>

5	Acudir con prontitud al médico especializado en las lesiones de la piel (dermatólogo)
---	---

Fuente: Aure (2022).

Breve análisis: las principales medidas para emitir un diagnóstico temprano ante un melanoma se basa tanto en la auto inspección frecuente como en la asistencia a un chequeo dermatológico rutinario, para de esta manera dejar en evidencia si ha aparecido algún lunar nuevo o si alguno ya existente ha evolucionado, características fundamentales en la identificación de lesiones malignas en la piel.

5. En su entorno laboral, ¿Aplican herramientas computacionales para agilizar procesos en los diagnósticos que realizan?

Tabla 5. Respuesta pregunta n° 5 entrevista.

Informante Clave N°	Respuestas
1	No se usan
2	No
3	No, no se aplican
4	No
5	No

Fuente: Aure (2022).

Breve análisis: con estas repuestas se hace notar que los médicos dermatólogos no utilizan herramientas computacionales para realizar los diagnósticos.

6. En su experiencia personal y profesional, ¿De qué manera cree que ayudaría a los pacientes una herramienta computacional de predicción, para la identificación de melanomas a partir de una imagen?

Tabla 6. Respuesta pregunta n° 6 entrevista.

Informante Clave N°	Respuestas
------------------------	------------

1	Sería útil para encender las alarmas a tiempo y que los pacientes asistan a la consulta cuando haya una predicción de melanoma
2	Serviría como guía para los pacientes al momento de realizar una auto examinación
3	Ayudaría muchísimo, porque los pacientes podrían detectar de forma precoz a través de imágenes si tienen alguna lesión similar
4	Puede orientar a los pacientes para que acudan con premura ante una lesión sospechosa y así tomar las medidas de forma oportuna.
5	Sería de muchísima ayuda, puesto que permitiría al paciente identificar con prontitud el melanoma y así poder acudir al especialista y seguir las recomendaciones del mismo.

Fuente: Aure (2022).

Breve análisis: los especialistas aseguran que una herramienta de predicción sería de gran utilidad, debido que los pacientes podrían detectar de manera precoz el melanoma. Esto asegura que el sistema planteado sería provechoso.

7. ¿Cómo se evaluaría la calidad de un software de predicción para la identificación de melanomas a partir de una imagen?

Tabla 7. Respuesta pregunta n° 7 entrevista.

Informante Clave N°	Respuestas
1	Se tendría que hacer una tabla con las predicciones correctas e incorrectas del software para obtener el porcentaje de aciertos y desaciertos.
2	Habría que comparar las predicciones con el diagnóstico médico.

3	Se podría evaluar por la cantidad de pacientes que logren manejar la aplicación
4	Tendríamos que cotejar los resultados emitidos por el software con el diagnóstico definitivo histopatológico (emitido por anatomía patológica posterior a una biopsia).
5	Se debería evaluar mediante la comparación de los resultados arrojados por el software y el diagnóstico médico.

Fuente: Aure (2022).

Breve análisis: entre estas respuestas, se evidencian dos puntos de vista importantes. En primera instancia, la manejabilidad del sistema por parte de los usuarios, y por otro lado, la comparación de predicciones del sistema con diagnósticos histopatológicos. Estas son claves importantes para el sistema, debido a que la única manera de dar un diagnóstico definitivo es con mediante este examen histopatológico.

8. ¿Cuál cree usted que sería el principal inconveniente a la hora de implementar un software de predicción para la identificación de melanomas a partir de una imagen?

Tabla 8. Respuesta pregunta n° 8 entrevista.

Informante Clave N°	Respuestas
1	Los usuarios deben saber que el diagnostico final sobre una marca en la piel solo lo puede dar un dermatólogo, ya que este tipo de software puede confundirlos
2	Si genera una predicción errónea podría llevar al paciente a creer que está sano y no lo está, y viceversa.
3	El principal inconveniente sería el internet, y que debe ser un programa sencillo para que la gente pueda manejarlo
4	Puede preocupar que el software emita un resultado negativo para malignidad y resulte que si sea, ocasionando que el

	paciente no acuda a tiempo. Por otro lado puede suceder lo contrario, diagnosticar melanoma cuando no lo hay representando un aumento en los gastos de salud.
5	Considero temible que el software dé un resultado equivocado, mostrando como benigno el lunar que en verdad es maligno. Dicho error ocasionaría que el paciente se fíe en ello y no acuda al médico; si pasa lo opuesto, representaría para el paciente un incremento en sus gastos del cuidado de la salud.

Fuente: Aure (2022).

Breve análisis: estas respuestas evidencian que los mayores inconvenientes son la accesibilidad al sistema, y una predicción errónea de melanoma o un falso negativo.

4.2. Fase II: Determinación de los requerimientos funcionales y no funcionales inherentes al sistema de verificación de la presencia de patología en el tejido.

En esta fase, luego de los análisis correspondientes a los resultados de las preguntas realizadas en la entrevista y tomando en consideración las observaciones, comentarios e ideas realizadas, se procedió a definir los requerimientos funcionales y no funcionales para el sistema.

4.2.1. Actividad I: Análisis y definición de los requisitos funcionales y no funcionales del sistema.

Se realizó el análisis requerido de la información obtenida por las respectivas herramientas de recolección de datos, las cuales fueron descritas anteriormente, adicionalmente se tomó en cuenta cada una de las observaciones realizadas en el proceso de la entrevista, con el fin de definir lo mejor posible los requisitos funcionales y no funcionales.

A continuación, se presentan los requerimientos:

- **Requerimientos funcionales:**
 - Ingreso de imagen.
 - Predicción de malignidad de la lesión ingresada.
 - Bajo error entre las predicciones realizadas con la data de entrenamiento y la data de prueba.
- **Requerimientos no funcionales:**
 - Mantener un diseño uniforme en la interfaz en toda la plataforma.
 - Realizar todas las validaciones necesarias para garantizar la integridad de los datos ingresados en la plataforma.
 - Garantizar la escalabilidad del sistema mediante una adecuada documentación, diseño y desarrollo.

4.3. Fase III: Desarrollo de la arquitectura de red neuronal más apropiada para el reconocimiento de las lesiones.

Continuando con las fases de la metodología XP y luego de completar la fase de análisis y haber determinado los requerimientos funcionales y no funcionales del sistema, se continúa con el siguiente paso, y uno de los más importantes para este tipo de plataformas, el desarrollo de la arquitectura de la red neuronal.

Es importante acotar que las redes neuronales convolucionales tienen muchas características que se pueden modificar, y que no hay una ciencia exacta que dicte como se deben plantear, para llegar al diseño óptimo se debe hacer bastante ensayo y error. Además de establecer las capas de la red neuronal, se debe dar un valor a bastantes hiper-parámetros que afectan en gran medida el desempeño de la misma, como lo son el learning rate, la cantidad de neuronas por cada capa, el stride, el tamaño del filtro o kernel, el tamaño de la imagen que se va a ingresar.

4.3.1. Actividad I: Diseño de la red neuronal


Antes de comenzar a calibrar hiper-parámetros, se debe plantear una arquitectura de red neuronal apropiada. Debe tener capas suficientes para extraer

las características más importantes de la red, y también debe ser lo suficientemente ligera de manera que los recursos del computador no se agoten.

Para esto último se deben tomar algunos factores importantes: primero, el tamaño del lote de imágenes a ingresar, luego, la cantidad de neuronas por capa, y por último, la profundidad de la red.

Al momento de diseñar una red neuronal, lo más eficiente es que se debe procurar expandir la misma en todos estos factores de manera simultánea, técnica conocida como compound scaling.

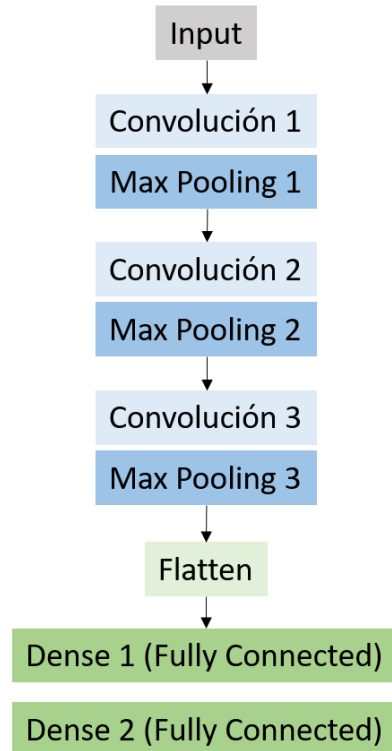
Gráfico 1. Compound Scaling.



Fuente: Tan et al. (2019).

Tomando en cuenta estas observaciones, y la capacidad computacional con la cual se dispone, la arquitectura de la red neural convolucional planteada es la siguiente:

Gráfico 2. Arquitectura de la red neuronal.



Fuente: Aure (2022).

4.3.2. Actividad II: Codificación de la red neuronal

Para la codificación de la red neuronal, se utilizó la biblioteca Tensorflow, la misma facilita en gran medida la tarea del desarrollo, ya que contiene una amplia variedad de funcionalidades y clases que se utilizan en la práctica.

En primera instancia, para lo avanzado hasta esta fase, se codificó la red tal cual como se planteó en el diseño:

Gráfico 3. Implementación de la arquitectura de la red en código.

```
model.add(Conv2D(64, (3,3), 1, activation='relu', input_shape=(224,224,3)))
model.add(MaxPooling2D(pool_size=(2,2)))

model.add(Conv2D(128, (3,3), 1, activation='relu', padding='same'))
model.add(MaxPooling2D(pool_size=(2,2)))

model.add(Conv2D(64, (3,3), 1, activation='relu', padding='same'))
model.add(MaxPooling2D(pool_size=(2,2)))

model.add(Flatten())

model.add(Dense(400, activation='relu'))
model.add(Dropout(0.5))
model.add(Dense(1, activation='sigmoid'))
```

Fuente: Aure (2022).

Los valores dentro de cada una de estas capas son los conocidos como hiper parámetros, y se deben ajustar acorde a lo obtenido en la fase de entrenamiento y pruebas, donde se explicará con mayor detalle este proceso.

4.4. Fase IV: Entrenamiento de la red neuronal dándole muestras de imágenes mostrando lunares benignos y melanomas cancerígenos.

Al momento de desarrollar una red neuronal, la fase de codificación y entrenamiento están estrechamente relacionadas, es el entrenamiento de la red la cual nos arrojará información clave para realizar los cambios pertinentes a los parámetros de la red neuronal.

4.4.1 Actividad I: Determinación de las imágenes para entrenamiento y validación.

El factor más importante del entrenamiento es sin duda alguna la data. Se debe elegir un conjunto de datos suficiente, y representativo, de manera que la red neuronal encuentre los patrones necesarios para emitir una predicción acertada.


Para el entrenamiento de la red neuronal, se eligió un banco de imágenes público encontrado en el archivo del ISIC llamado HAM10000. Este banco de

imágenes incluye una colección representativa de todas las categorías de diagnósticos importantes en el ámbito de las lesiones de piel pigmentadas. Más del 50% de las lesiones se confirmaron mediante un diagnóstico histopatológico, el resto se ratificó a través del seguimiento, consenso de expertos, o examinación microscópica in-vivo.

El banco de imágenes cuenta con un total de 10005 fotografías, de las cuales 6705 corresponden a lunares, y 1113 a melanomas. Para que el entrenamiento de una red sea más efectivo, se debe procurar tener una cantidad balanceada de imágenes de cada categoría, en este caso tenemos una gran diferencia de 5592 imágenes. Como se mencionó anteriormente, durante la fase de diagnóstico se hizo una investigación sobre programas similares, los cuales están publicados en la página de Kaggle. En esta plataforma, los usuarios también publican data para el entrenamiento de redes neuronales, y allí se encontró el banco de imágenes HAM10000 balanceado mediante data augmentation.

El data augmentation es una técnica para ampliar la cantidad de datos que se poseen para el entrenamiento de la red, consiste en realizar cambios a la imagen que no alteren su representación, como rotaciones sobre el mismo eje, giros de 90 grados, cambios de saturación, entre otros.

Gráfico 4. Imágenes luego de aplicar data augmentation.



Fuente: Aure. (2022)

Aplicando esta técnica al grupo de imágenes diagnosticadas como melanoma, se logró obtener un total de 6678 ejemplares, quedando así las dos categorías separadas por solo 27 fotos por el lado de los lunares.

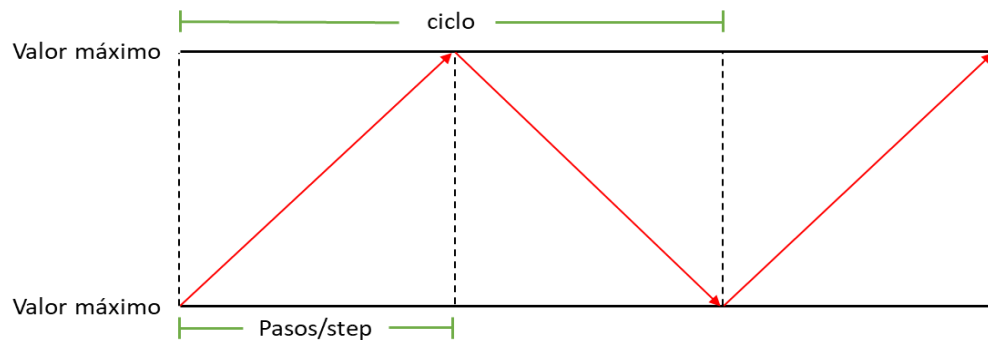
4.4.2 Actividad II: Determinación de una velocidad de entrenamiento óptima.

La velocidad de entrenamiento, o learning rate, es el hiper parámetro más importante de definir. Esta controla la rapidez a la que el modelo se adapta al problema mediante la actualización de los pesos del mismo. Un learning rate muy grande puede causar una convergencia muy veloz a un mínimo no óptimo de la función de pérdida, mientras que uno muy pequeño podría causar que el proceso de entrenamiento se estanque.

Existen muchas técnicas para encontrar un learning rate óptimo, entre estas técnicas se ha descubierto que establecer un valor cíclico a la rapidez de aprendizaje es la mejor opción. Esto consiste en hacer al learning rate oscilar

entre un valor máximo y un valor mínimo en una cantidad de épocas de entrenamiento establecidas, y de esta manera, lograr que el modelo converja de manera rápida y precisa a un mínimo óptimo sin tener que realizar tantas pruebas y reduciendo significativamente la cantidad de épocas de entrenamiento.

Gráfico 5: explicación del Cyclic Learning Rate Scheduler.



Fuente: Aure. (2022)

Por ello se decidió implementar la técnica de Cycle Learning Rate Schedule para optimizar el entrenamiento de la red neuronal.

Gráfico 5. Implementación del Cyclic Learning Rate Scheduler (1).

```
class CosineAnnealer:
    def __init__(self, start, end, steps):
        self.start = start
        self.end = end
        self.steps = steps
        self.n = 0

    def step(self):
        self.n += 1
        cos = np.cos(np.pi * (self.n / self.steps)) + 1
        return self.end + (self.start - self.end) / 2. * cos
```

Fuente: Aure. (2022)

Gráfico 6. Implementación del Cyclic Learning Rate Scheduler (2).

```
class OneCycleScheduler(Callback):

    def __init__(self, lr_max, steps, mom_min=0.85, mom_max=0.95, phase_1_pct=0.3, div_factor=25.):
        super(OneCycleScheduler, self).__init__()
        lr_min = lr_max / div_factor
        final_lr = lr_max / (div_factor * 1e4)
        phase_1_steps = steps * phase_1_pct
        phase_2_steps = steps - phase_1_steps

        self.phase_1_steps = phase_1_steps
        self.phase_2_steps = phase_2_steps
        self.phase = 0
        self.step = 0

        self.phases = [[CosineAnnealer(lr_min, lr_max, phase_1_steps), CosineAnnealer(mom_max, mom_min, phase_1_steps)],
                       [CosineAnnealer(lr_max, final_lr, phase_2_steps), CosineAnnealer(mom_min, mom_max, phase_2_steps)]]

        self.lrs = []
        self.moms = []

    def on_train_begin(self, logs=None):
        self.phase = 0
        self.step = 0

        self.set_lr(self.lr_schedule().start)
        self.set_momentum(self.mom_schedule().start)

    def on_train_batch_begin(self, batch, logs=None):
        self.lrs.append(self.get_lr())
        self.moms.append(self.get_momentum())

    def on_train_batch_end(self, batch, logs=None):
        self.step += 1
        if self.step >= self.phase_1_steps:
            self.phase = 1

        self.set_lr(self.lr_schedule().step())
        self.set_momentum(self.mom_schedule().step())
```

Fuente: Aure. (2022)

Gráfico 7. Implementación del Cyclic Learning Rate Scheduler (3).

```
def get_lr(self):
    try:
        return tf.keras.backend.get_value(self.model.optimizer.lr)
    except AttributeError:
        return None

def get_momentum(self):
    try:
        return tf.keras.backend.get_value(self.model.optimizer.momentum)
    except AttributeError:
        return None

def set_lr(self, lr):
    try:
        tf.keras.backend.set_value(self.model.optimizer.lr, lr)
    except AttributeError:
        pass # ignore

def set_momentum(self, mom):
    try:
        tf.keras.backend.set_value(self.model.optimizer.momentum, mom)
    except AttributeError:
        pass # ignore

def lr_schedule(self):
    return self.phases[self.phase][0]

def mom_schedule(self):
    return self.phases[self.phase][1]

def plot(self):
    ax = plt.subplot(1, 2, 1)
    ax.plot(self.lrs)
    ax.set_title('Learning Rate')
    ax = plt.subplot(1, 2, 2)
    ax.plot(self.moms)
    ax.set_title('Momentum')
```

Fuente: Aure. (2022)

4.4.3 Actividad III: Determinación de los hiper parámetros adecuados.

Luego de haber establecido la rapidez de aprendizaje, es necesario especificar los valores del resto de los hiper parámetros de la red neuronal. Existen muchos, y para cada red se usan diferentes según el propósito de la misma.

Debido a la gran cantidad de parámetros a optimizar, poner a prueba todos estos requeriría una cantidad de recursos computacionales muy grandes, y llevaría demasiado tiempo, por ello, antes de realizar una búsqueda exhaustiva de cuáles eran los mejores hiper parámetros, se definieron algunos para mantener un estándar y dejarlos fijados, de manera que el resto del proceso pudiese ser completado en el espacio de tiempo establecido.

Los hiper parámetros pre-establecidos, fueron:

- El tamaño de los kernels de las capas convolucionales: los mismos son una matriz de ciertas dimensiones, que sirve como filtro que “escanea” a toda la imagen, y define los valores más relevantes dentro del área que abarca.
- El stride: esta es la cantidad de pixeles que el kernel se moverá en cada paso durante su recorrido sobre la imagen.
- Inicializador del kernel: los pesos utilizados por la red para clasificar la imagen cambian en cada época. Los inicializadores del kernel se encargan de que estos no sufran cambios muy volátiles.
- Funciones de activación: las funciones de activación se encargan de determinar el valor de salida de una red neuronal, restringen los valores dentro de un rango establecido.

Para el pre establecimiento de estos hiper parámetros se realizó una investigación de cuáles eran los mejores valores, y cuáles eran los más utilizados, así como también cuales de estos se utilizaban en otras redes neuronales para la clasificación de imágenes.

Keras tiene un framework llamado keras.tuner, este sirve para probar diversos hiper parámetros y comparar los resultados de todos de manera automática. A la red planteada anteriormente se le hicieron pruebas de control para determinar valores de referencia, y luego se implementó keras.tuner para buscar los mejores hiper parámetros para su entrenamiento.

Gráfico 8. Definición de función constructora del modelo con parámetros variables para la aplicación de keras.tuner.

```
[ ] def model_builder(hp):
    model = Sequential()
    hp_neurons1 = hp.Choice('neurons_1', values=[16, 32, 64])
    hp_neurons2 = hp.Choice('neurons_2', values=[32, 64, 128])
    hp_neurons3 = hp.Choice('neurons_3', values=[64, 128, 256])
    hp_neurons4 = hp.Choice('neurons_4', values=[200, 300, 400])
    hp_dropoutrate = hp.Choice('dropoutrate', values=[0.2, 0.3, 0.5])

    model.add(Conv2D(hp_neurons1, (3,3), 1, activation='relu',
                    kernel_initializer='he_uniform', input_shape=(224,224,3)))
    model.add(MaxPooling2D(pool_size=(2,2)))

    model.add(Conv2D(hp_neurons2, (3,3), 1, activation='relu', kernel_initializer='he_uniform'))
    model.add(MaxPooling2D(pool_size=(2,2)))

    model.add(Conv2D(hp_neurons3, (3,3), 1, activation='relu', kernel_initializer='he_uniform'))
    model.add(MaxPooling2D(pool_size=(2,2)))

    model.add(Flatten())

    model.add(Dense(hp_neurons4, kernel_initializer='he_uniform', activation='relu'))
    model.add(Dropout(hp_dropoutrate))
    model.add(Dense(1, kernel_initializer='he_uniform', activation='sigmoid'))

    opt = tf.keras.optimizers.Adam(beta_1 = 0.9, beta_2 = 0.999, epsilon = 1)
    model.compile(loss=tf.losses.BinaryCrossentropy(),
                optimizer=opt,
                metrics=['accuracy'])

    return model
```

Fuente: Aure. (2022)

Gráfico 9. Inicialización del buscador de hiper parámetros óptimos.

```
[ ] tuner = kt.Hyperband(model_builder,
                        objective='val_accuracy',
                        max_epochs=100,
                        factor=3,
                        directory='dir',
                        project_name='x')
```

Fuente: Aure. (2022)

Gráfico 10. Retornos de la función tuner.search (1)

```
[ ] tuner.search(x_trained, y_train_hot , batch_size=50,  
                validation_data = (x_tasted, y_test_hot),  
                epochs=100,  
                callbacks = [stop_early])
```

```
Trial 254 Complete [00h 03m 33s]  
val_accuracy: 0.8207617402076721
```

```
Best val_accuracy So Far: 0.8633308410644531  
Total elapsed time: 07h 03m 46s
```

Fuente: Aure. (2022)

Gráfico 11. Retornos de la función tuner.search (2)

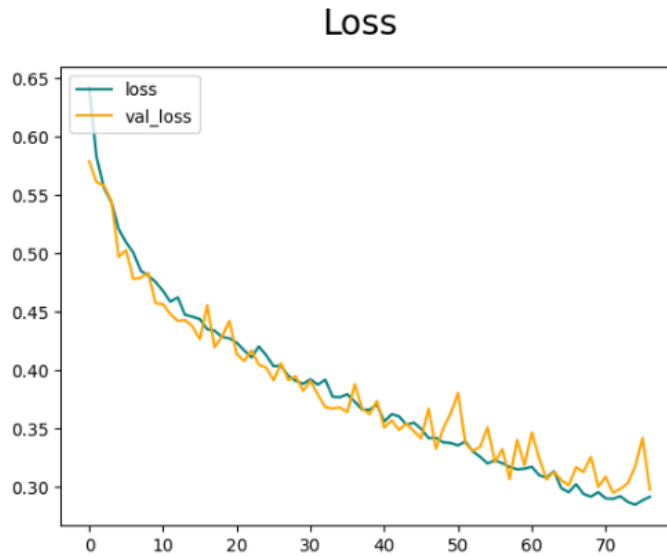
Value	Best Value So Far	Hyperparameter
32	32	neurons_1
128	32	neurons_2
128	128	neurons_3
200	300	neurons_4
0.5	0.2	dropoutrate
100	100	tuner/epochs
34	34	tuner/initial_epoch
4	4	tuner/bracket
4	4	tuner/round
0143	0145	tuner/trial_id

Fuente: Aure. (2022)

4.4.4. Actividad IV: entrenamiento de la red neuronal con los valores obtenidos.

Luego de obtener los mejores parámetros para la arquitectura de red planteada, se procedió a entrenar la misma. Para esto, se separaron los datos en 60% para entrenamiento, 20% para validación y 20% para pruebas.


Gráfico 12. Función de pérdida durante el entrenamiento.



Fuente: Aure. (2022)

Se puede observar que tanto la función de pérdida, como la de pérdida de validación, son decrecientes. Este es el comportamiento esperado para una red que este mejorando su precisión.

Gráfico 13. Función de precisión durante el entrenamiento.



Fuente: Aure. (2022)

4.5. Fase V: Realización de pruebas a la red neuronal ingresando imágenes ya clasificadas y comparando los resultados dados por la red con el diagnostico ya establecido.

Para finalizar, se realizaron pruebas para determinar la precisión real del modelo con imágenes que no ha “visto”. Para ello, se ingresaron un total de 2670 imágenes, de las cuales la mitad era de lunares y el resto de melanomas, y se ingresaron en la misma llevando el control de tres indicadores:

- Precision: esta variable mide que tan precisa fue la red neuronal clasificando de manera positiva alguna imagen, es decir, del total de predicciones, cual es la relación de verdaderos positivos y positivos totales.

$$Precision = \frac{Verdadero\ Positivo}{Verdadero\ Positivo + Falso\ Positivo}$$

- Recall: con el recall se calcula cuantos de los positivos se determinaron de manera real, por lo tanto, es la relación entre verdaderos positivos, y positivos tanto verdaderos como falsos.

$$Recall = \frac{Verdadero\ Positivo}{Verdadero\ Positivo + Falso\ Negativo}$$

- Accuracy: esta variable sólo mide el promedio de imágenes clasificadas de manera correcta.

Los indicadores mencionados son de gran importancia, ya que si el modelo solo predice que las imágenes son melanomas, estaría arrojando un 50% de precisión si únicamente se mide el promedio de las imágenes clasificadas correctamente.

Luego de haber hecho las pruebas a la red neuronal, las métricas arrojadas dieron los siguientes resultados:

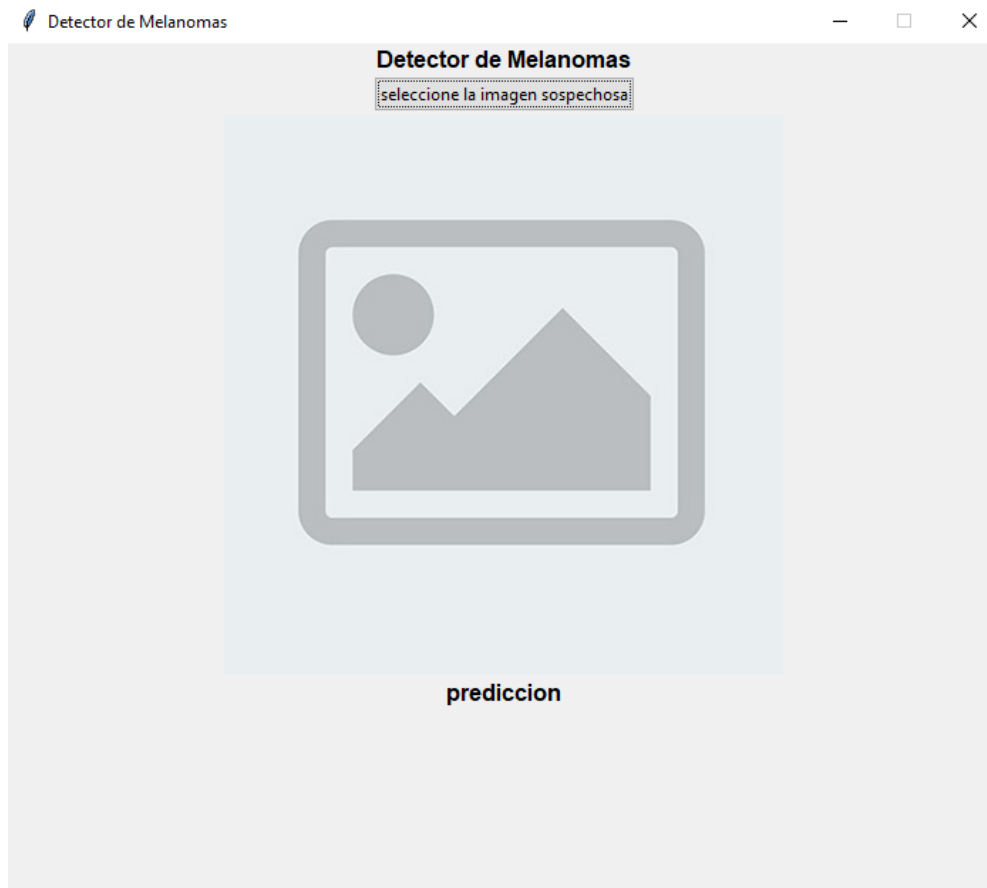
- Precision: 0.8697639107704163
- Recall: 0.8784615397453308
- Accuracy: 0.8750474452972412

Esto quiere decir, que la clasificación de imágenes está siendo exitosa, aproximadamente en un 87% de los casos.

4.5.1. Actividad I: Implementación de la red en un programa local con interfaz

Para finalizar, y facilitar el uso y pruebas de la red neuronal por el usuario, se implementó el mismo en una aplicación local donde se pueden seleccionar imágenes del computador para luego emitir una predicción sobre la misma, y que el resultado se obtenga en pantalla.

Gráfico 14. Interfaz inicial del sistema.



Fuente: Aure. (2022)

Gráfico 15. Interfaz del sistema con predicción exitosa de lunar emitida.



Fuente: Aure. (2022)

Gráfico 16. Interfaz del sistema con predicción exitosa de melanoma emitida.



Fuente: Aure. (2022)

CONCLUSIONES Y RECOMENDACIONES

Conclusiones

Luego de examinar los resultados obtenidos en cada una de las fases ya descritas, junto con el desarrollo y despliegue del sistema, con sus respectivas pruebas, se llegó a una serie de desenlaces relacionados a los objetivos definidos en la presente investigación.

En la fase inicial o primera fase referente a la cuantificación de las variables que intervienen en la identificación de melanomas en la piel, aplicando técnicas de recolección de datos, se logró realizar una evaluación para la elaboración de sistemas de predicción para la detección de las lesiones, donde se logró examinar herramientas existentes para realizar ciertas funciones, además de conceptualizar los parámetros necesarios que determinan si una marca en la piel podría ser una lesión maligna de tipo melanoma.

En la segunda fase se logró determinar, haciendo uso del recurso de recolección de datos, los requerimientos que debía presentar el sistema desarrollado, comenzando con los requerimientos funcionales del sistema, los cuales son, ingreso de imagen, predicción de malignidad de la lesión ingresada y bajo error entre las predicciones realizadas con la data de entrenamiento y la data de prueba. Debido a que el aspecto fundamental del sistema es la red neuronal y las predicciones, los requerimientos funcionales están dirigidos a una implementación sencilla del modelo para cerciorar un correcto funcionamiento e integridad de datos.

Con respecto a los requerimientos no funcionales, se determinaron como bases fundamentales la realización de todas las validaciones necesarias para garantizar la integridad de los datos ingresados en la plataforma, y garantizar la escalabilidad del sistema mediante una adecuada documentación, diseño y desarrollo, aspectos fundamentales para que la red cuente con datos íntegros para realizar las predicciones, y que el proyecto sea escalable en investigaciones futuras.

En la tercera fase, se estableció el diseño de la arquitectura de la red neuronal para la identificación de posibles melanomas mediante una adaptación de la metodología XP, y se realizó el desarrollo inicial del modelo utilizando herramientas computacionales como el lenguaje programación Python, la biblioteca Tensorflow y el framework Keras que se ejecuta para Tensorflow y así agilizar el proceso de desarrollo del modelo, todos estos apoyados por módulos como lo son opencv y matplotlib.

En la cuarta fase, se realizó el entrenamiento de la red neuronal, para el cual se realizó la separación inicial de los datos en lunares y melanomas según la metadata recolectada y se pre procesó la misma para asegurar que todas tuviesen una relación de anchura y altura equivalentes, de esta misma manera, las fotografías de melanomas fueron sometidas a un proceso de aumento de datos, durante el cual se realizaron modificadores de rotación para obtener un balance adecuado entre la cantidad de data correspondiente a lesiones malignas con la data de lunares.

Luego, se realizaron diversas pruebas exhaustivas a la arquitectura de la red neuronal para establecer los mejores hiper parámetros en las capas del modelo para finalmente entrenar a la red con los mismos.

En la última fase, según lo estipulado en el trabajo de grado, se realizaron pruebas para determinar la precisión real del modelo mediante el ingreso de 2670 imágenes de prueba a la red neuronal para su clasificación, y se establecieron métricas para el cálculo de la relación entre predicciones falsas y predicciones acertadas.

Para finalizar, se implementó el modelo entrenado de la red neuronal convolucional en una aplicación local utilizando Tkinter.

Con el desarrollo de esta aplicación, se podría salvar miles de vidas a personas que posean una melanoma en la piel, y las mismas se encuentren inadvertidos ante su malignidad, siendo esta la principal causa por la cual los afectados no asisten a tiempo ante un especialista.

Si bien se sabe que el diagnóstico definitivo solo puede ser emitido por un profesional de la salud, el hecho de encender las alarmas a tiempo es un factor decisivo para el futuro de una persona con este tipo de lesión.

Recomendaciones

En relación con la información que se obtuvo durante el desarrollo de las fases de proyecto, estructuradas mediante la metodología XP, para futuras aplicaciones del sistema propuesto, se recomienda aplicar las recomendaciones expuestas a continuación:

Teniendo en cuenta que los sistemas computacionales se encuentran en constante evolución y cambio, es importante tener en cuenta que los requisitos funcionales y no funcionales varían con el tiempo y según el tipo de sistema en el cual se implemente la red neuronal

Al momento de desarrollar redes neuronales convolucionales para la clasificación de imágenes, el factor más importante es la calidad y la cantidad de datos que poseamos para su entrenamiento, por lo cual, tener acceso a un banco de imágenes es fundamental, y luego, que las mismas sean representativas de su categoría y se hayan capturado de una manera clara. Esta será una parte fundamental para que el modelo capte verdaderamente las características que representan a un melanoma comparado con un lunar.

Teniendo en cuenta la recomendación anterior, también pueden ser adicionados nuevos parámetros para el aprendizaje de las redes neuronales, tales como los antecedentes clínicos personales y familiares de cada usuario, así como la edad, género y origen racial.

Por último, para incrementar la facilidad de uso y el alcance del mismo, se podría implementar el modelo de red neuronal ya entrenado en una aplicación móvil o un sistema web.

REFERENCIAS BIBLIOGRÁFICAS

- Álvaro Díaz, M. (2020). **Optimización de una red neuronal convolucional para la detección de melanomas en imágenes dermoscópicas.**
ETSSIS_Telecomunicacion.
- Arias, F. G. (2006). **El proyecto de investigación.** 6ta Edición. Caracas. Editorial: Episteme.
- Brownlee, J. (2019, enero 8). **A gentle introduction to the rectified linear unit (ReLU).** Machine Learning Mastery.
<https://machinelearningmastery.com/rectified-linear-activation-function-for-deep-learning-neural-networks/>
- Bishop, Christopher M. (2006). **Pattern Recognition and Machine Learning.**
Springer.
- Celli, M. E. (2014). **Diseño de un programa de formacion para la responsabilidad social universitaria.**
- Corporativa, I. (s/f). **Descubre los principales beneficios del Machine Learning.**
Iberdrola. Recuperado el 12 de abril de 2022, de
<https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatico>
- Curti B.D., & Leachman S, & Urba W.J. (2018). **Cáncer de la piel.** Jameson J, & Fauci A.S., & Kasper D.L., & Hauser S.L., & Longo D.L., & Loscalzo J(Eds.), **Harrison. Principios de Medicina Interna**, 20e. McGraw Hill.
- Duran, F. (s/f). **Guia de Programacion en Python**
- Geron, A. (2017). **Hands-on machine learning with scikit-learn and TensorFlow.**
O'Reill Media.
- Google [google]. (2015, noviembre 9). **TensorFlow: Open source machine learning.**
Youtube. https://www.youtube.com/watch?v=oZikw5k_2FM

- Gour, M., & Jain, S. (2020). **Stacked convolutional neural network for diagnosis of COVID-19 disease from X-ray images.** arXiv [eess.IV]. <https://doi.org/10.48550/ARXIV.2006.13817>
- Heenaye-Mamode Khan, M., Boodoo-Jahangeer, N., Dullull, W., Nathire, S., Gao, X., Sinha, G. R., & Nagwanshi, K. K. (2021). **Multi- class classification of breast cancer abnormalities using Deep Convolutional Neural Network (CNN).** PloS One, 16(8), e0256500. <https://doi.org/10.1371/journal.pone.0256500>
- jesustrera.com. (s/f). Jesusutrera.com. Recuperado el 3 de mayo de 2022, de <http://jesustrera.com/articles/article04.html>
- KerasTuner. (s/f). Keras.Io. Recuperado el 21 de septiembre de 2022, de https://keras.io/keras_tuner/
- Khandelwal, R. (2020, agosto 20). **Loading custom image dataset for Deep learning models: Part 1. Towards Data Science.** <https://towardsdatascience.com/loading-custom-image-dataset-for-deep-learning-models-part-1-d64fa7aeca6>
- Man against machine: **AI is better than dermatologists at diagnosing skin cancer.** (s/f). ScienceDaily. Recuperado el 3 de mayo de 2022, de <https://www.sciencedaily.com/releases/2018/05/180528190839.htm>
- Melanoma - My own convnet.** (2018, diciembre 2). Kaggle.com; Kaggle. <https://www.kaggle.com/code/drscarlat/melanoma-my-own-convnet/notebook>
- Melanoma skin cancer statistics. (s/f). Cancer.Org. Recuperado el 4 de mayo de 2022, de <https://www.cancer.org/cancer/melanoma-skin-cancer/about/key-statistics.html>
- Sagar, A., & Jacob, D. (2020). **Convolutional neural networks for classifying melanoma images.** En bioRxiv. <https://doi.org/10.1101/2020.05.22.110973>
- Sisco, Y. (2019). **Reconocimiento facial combinando técnicas de extracción de características con redes neuronales convolucionales.** Universidad Central de Venezuela.

- Shung, K. P. (2018, marzo 15). **Accuracy, precision, recall or F1? Towards Data Science**. <https://towardsdatascience.com/accuracy-precision-recall-or-f1-331fb37c5cb9>
- SIIM-ISIC melanoma classification. (s/f). Kaggle.com. Recuperado el 10 de septiembre de 2022, de <https://www.kaggle.com/competitions/siim-isic-melanoma-classification/data?select=train>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn: **Machine Learning in Python**. Journal of machine learning research: JMLR, 12(85), 2825–2830. <https://jmlr.org/papers/v12/pedregosa11a.html>
- Tejada Layme, G. M., & Gonzales Chama, R. P. (2020). **Arquitectura de red neuronal convolucional para diagnóstico de cáncer de piel**. Universidad Tecnológica del Perú.
- (S/f). Researchgate.net. Recuperado el 15 de abril de 2022, de https://www.researchgate.net/publication/359446075_Image_Masking_and_Enhancement_System_for_Melanoma_Early_Stage_Detection
- van Wyk, A. (2019, septiembre 2). **Super-convergence in Tensorflow 2 with the 1Cycle policy**. Avanwyk. <https://www.avanwyk.com/tensorflow-2-super-convergence-with-the-1cycle-policy/>