

PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR

FACULTAD DE INGENIERÍA



TEMA:

DESARROLLO DE UN ALGORITMO BASADO EN REDES NEURONALES PARA LA IDENTIFICACIÓN AUTOMÁTICA DEL MELANOMA MEDIANTE EL ANÁLISIS DE IMÁGENES

AUTOR:

JOSE ALBERTO LEÓN ALARCÓN

DIRECTOR:

CHARLES EDISON ESCOBAR TERAN

TRABAJO PREVIO A LA OBTENCIÓN DEL TÍTULO DE MAGISTER EN SISTEMAS DE INFORMACIÓN MENCIÓN EN DATA SCIENCE

QUITO, enero de 2025

DEDICATORIA

Cada una de mis metas personales y profesionales son y serán dedicadas a mi abuelo, y esta no es la excepción. Además, sumo a esta dedicatoria a mi tío, quien hoy acompaña a mi abuelo. Su influencia sigue siendo una luz que guía mi camino. Asimismo, su legado vive en cada uno de mis logros y en cada página de este trabajo.

Mis padres, pilares fundamentales de superación, cuyo amor incondicional y apoyo constante han sido primordiales en cada paso de mi camino. Su confianza en mí y sus enseñanzas han sido la base sobre la que he construido este logro. Este trabajo es tanto suyo como mío.

Mis hermanas, donde su alegría y compañía han iluminado mi vida de maneras que nunca podré expresar completamente. Esperando ser una fuente de inspiración para sus logros y metas.

Así también, a Melanie Tumbaco, tu presencia en mi vida ha hecho que cada desafío sea más fácil de superar y cada alegría más intensa de celebrar. Gracias por tu paciencia, tu comprensión y por hacer cada momento especial.

ÍNDICE

DEDICATORIA	I
ÍNDICE.....	II
ÍNDICE DE ILUSTRACIONES	V
ÍNDICE DE TABLAS.....	VI
RESUMEN.....	VII
CAPÍTULO I: INTRODUCCIÓN	1
1. INTRODUCCIÓN.....	1
1.1. ANTECEDENTES	1
1.2. PLANTEAMIENTO DEL PROBLEMA.....	2
1.3. JUSTIFICACIÓN.....	3
1.4. OBJETIVOS.....	4
1.4.1. OBJETIVO GENERAL	4
1.4.2. OBJETIVOS ESPECÍFICOS.....	4
CAPÍTULO II: FUNDAMENTACIÓN TEÓRICA	5
2. MARCO TEÓRICO Y CONCEPTUAL	5
2.1. INTRODUCCIÓN AL DIAGNÓSTICO DERMATOLÓGICO	5
2.2. MELANOMA: CANCER DE LA PIEL	7
2.2.1. DIAGNÓSTICO CLÍNICO.....	7
2.3. FUNDAMENTOS DE INTELIGENCIA ARTIFICIAL.....	9
2.3.1. INTELIGENCIA ARTIFICIAL.....	9
2.3.2. APLICACIONES DE LA IA EN LA MEDICINA	10
2.3.3. APRENDIZAJE AUTOMÁTICO.....	12
2.3.3.1. APRENDIZAJE SUPERVISADO.....	12
2.3.3.2. APRENDIZAJE NO SUPERVISADO.....	12
2.3.3.3. APRENDIZAJE POR REFUERZO.....	12

2.3.4.	APRENDIZAJE PROFUNDO.....	12
2.3.5.	REDES NEURONALES.....	13
2.3.5.1.	REDES NEURONALES ARTIFICIALES	13
2.3.5.2.	REDES NEURONALES CONVOLUCIONALES.....	14
2.3.5.3.	REDES NEURONALES RECURRENTE.....	16
2.4.	APLICACIONES DE REDES NEURONALES EN MEDICINA.....	17
CAPÍTULO III: METODOLOGÍA Y TÉCNICAS.....		21
3.	DESARROLLO DE UN ALGORITMO CON REDES NEURONALES PARA LA IDENTIFICACIÓN DEL MELANOMA.....	21
3.1.	REVISIÓN DE LA LITERATURA	21
3.1.1.	INTRODUCCIÓN A LA CLASIFICACIÓN DE IMÁGENES MÉDICAS 21	
3.1.2.	ESTUDIOS PREVIOS EN CLASIFICACIÓN DE MELANOMA	22
3.1.3.	MÉTODO DE PROCESAMIENTO Y AUMENTO DE DATOS.....	22
3.1.4.	ARQUITECTURA DE REDES NEURONALES	23
3.2.	RECOPIACIÓN Y PROCESAMIENTO DE DATOS.	23
3.2.1.	RECOPIACIÓN DE DATOS.....	23
3.2.2.	DESCRIPCIÓN DE LOS DATOS.....	23
3.2.3.	PROCESAMIENTO DE DATOS.....	26
3.3.	DISEÑO DE LA ARQUITECTURA DE RED NEURONAL.....	31
3.4.	ENTRENAMIENTO DEL MODELO	33
CAPÍTULO IV: RESULTADOS Y DISCUSIÓN.....		37
4.	RESULTADOS Y DISCUSIÓN	37
4.1.	EVALUACIÓN DEL MODELO DE RED NEURONAL.....	37
CAPÍTULO V: CONCLUSIONES Y RECOMENDACIONES.....		43
5.	CONCLUSIONES Y RECOMENDACIONES.....	43
5.1.	CONCLUSIONES.....	43

5.2. RECOMENDACIONES.....	44
BIBLIOGRAFÍA	46

ÍNDICE DE ILUSTRACIONES

Ilustración 1. Capas de la piel.....	5
Ilustración 2. Inspección del paciente.....	6
Ilustración 3. Esquema de una neurona biológica	14
Ilustración 4. Esquema de las capas CNN y FC	15
Ilustración 5. Diferencia entre Redes Recurrentes y Redes Feed-Forward ...	17
Ilustración 6. Arquitectura típica de una Red Neuronal Convolutiva para la clasificación de imágenes médicas.....	18
Ilustración 7. Imágenes de Melanoma y NotMelanoma	24
Ilustración 8. Cantidad de Imágenes en Dataset.....	25
Ilustración 9. Imagen de Melanoma.....	26
Ilustración 10. Imagen en escala de grises.....	27
Ilustración 11. Aplicación de Blackhat	27
Ilustración 12. Técnica de umbralización.....	28
Ilustración 13. Imagen en colores BGR.....	29
Ilustración 14. Aplicación del algoritmo DullRazor.....	29
Ilustración 15. Máscara de desenfoque	30
Ilustración 16. Imágenes procesadas.....	31
Ilustración 17. Gráfica de la pérdida de la validación y entrenamiento	38
Ilustración 18. Exactitud del entrenamiento y validación	39
Ilustración 19. Gráfico de curva ROC.....	40
Ilustración 20. Matriz de confusión	41

ÍNDICE DE TABLAS

Tabla 1. Criterios ABCDE para el diagnóstico de melanoma	8
Tabla 2. Argumentos de EarlyStopping	34
Tabla 3. Argumentos de ReduceLRonPlateau.....	34
Tabla 4. Parámetros de entrenamiento	35
Tabla 5. Valores de pérdida y exactitud.....	39
Tabla 6. Métricas de evaluación.....	42

RESUMEN

El presente trabajo tiene como propósito la implementación y desarrollo de un algoritmo basado en redes neuronales convolucionales, buscando optimizar la eficiencia y precisión en la identificación del Melanoma. Este incluye la revisión exhaustiva de la literatura para informar sobre el estado actual del campo de estudio, la recopilación y preparación de un banco de datos utilizando algoritmos y técnicas como DullRazor y Unsharp Masking, el diseño e implementación de una arquitectura de CNN adaptada a la detección del Melanoma y la evaluación del modelo propuesto mediante métricas de evaluación.

La evaluación del modelo demostró un funcionamiento superior en términos de clasificación de imágenes, obteniendo una exactitud del 97.77% en datos de prueba. Además, se reportaron métricas basadas en predicciones como: Precisión, exactitud, Recall, puntuación F1 las cuales obtuvieron valores altamente aceptables. Siendo así, este algoritmo de red neuronal convolucional resultó en una mejora significativa en la eficiencia y precisión del diagnóstico dermatológico.

Este proyecto no solo aborda una problemática clave en el diagnóstico del melanoma, sino que también presenta una contribución significativa al área emergente de la ciencia de datos aplicada a la salud. El resultado de este trabajo propiciaría una base para futuras investigaciones y desarrollos en la intersección entre la ciencia de datos y la medicina.

Palabras claves: Melanoma, Cáncer de Piel, Aprendizaje Profundo, Redes Neuronales Convolucionales

1. INTRODUCCIÓN

1.1. ANTECEDENTES

El diagnóstico clínico enfrenta un desafío persistente en la identificación precisa del melanoma presente en la piel. Aunque los expertos en la salud de la piel confían en su experiencia clínica y en métodos de diagnóstico visual, considerado un diagnóstico tradicional, esta aproximación presenta limitaciones inherentes que impactan en la calidad y fiabilidad del diagnóstico. Es por ello, que se plantea usar nuevas alternativas para diagnosticar dichas patologías, tales como el uso de inteligencia artificial.

De acuerdo con la investigación de (Venkatesh et al., 2024) menciona que: El diagnóstico dermatológico mediante inteligencia artificial (IA) ha dejado de limitarse al cáncer de piel para abarcar una amplia gama de enfermedades cutáneas comunes, lo que ofrece nuevos y apasionantes horizontes para la atención dermatológica. Hasta la fecha, la FDA (Food and Drug Administration) aún no ha aprobado ningún dispositivo de IA para el diagnóstico o el tratamiento dermatológico. Con el auge de la tele dermatología durante la pandemia de COVID-19, se ha generalizado la disponibilidad de nuevos bancos de datos de imágenes cutáneas para entrenar modelos.

De esta forma se han venido dando múltiples sistemas basados en inteligencia artificial que implementan estos bancos de datos para entrenar los modelos cada vez son más precisos, tal y como es el caso de (Galarza Zambrano y Romero Rodríguez, 2019) en su tesis titulada “Reconocimiento de imágenes para detección temprana de alteraciones posturales” donde presentan un sistema automatizado para detectar desviaciones de la columna vertebral en pacientes que se someten a radiografías lumbares. La finalidad principal fue calcular el ángulo de desviación de la columna vertebral a partir de una sola radiografía mediante el uso de una Red Neuronal Convolutiva (CNN). La CNN identifica la sección o máscara relevante para el análisis. La red se entrena utilizando radiografías con escoliosis, que luego se comparan con las radiografías previamente registradas en el sistema

para encontrar la región de interés. Posteriormente, se extrae el centro longitudinal de la columna en función de su forma y se ajusta la forma de la desviación mediante una regresión polinomial de octavo grado. La columna de cada paciente se contrasta con una columna en perfecto estado y se lleva a cabo un análisis tangencial de los puntos donde la columna interseca, tomando como referencia el punto de inicio y el punto final de la desviación. Este proceso determina automáticamente el grado de desviación de la columna del paciente. Al eliminar la intervención manual, el sistema elimina la arbitrariedad de encontrar las vértebras donde comienza y termina la deformidad espinal.

De igual forma, (Haddad y Hameed, 2018) en su artículo titulado “Image Analysis Model For Skin Disease Detection: Framework” se centra en el desarrollo de un marco de trabajo automatizado para la detección de enfermedades dermatológicas como Acné, Psoriasis, Melanoma, Sarpullido por calor, a partir de imágenes. El objetivo principal fue crear un sistema preciso y eficiente que pudiera auxiliar en el diagnóstico de estas afecciones. El marco de trabajo propuesto se basa en una red neuronal convolucional (CNN), la cual ha señalado ser altamente efectiva en tareas de reconocimiento de imágenes. Dicha solución puede ser implementada como una solución efectiva.

1.2. PLANTEAMIENTO DEL PROBLEMA

En el ámbito de la dermatología clínica, la identificación precisa y temprana del melanoma se erige como un desafío de suma relevancia. A pesar de los avances en la práctica médica, la escasez de métodos tradicionales para abordar la complejidad de las condiciones dermatológicas ha generado una brecha sustancial en la eficacia del diagnóstico. La interpretación visual y la experiencia clínica, pilares fundamentales en el proceso diagnóstico dermatológico, se ven limitadas por su inherente subjetividad. Siendo así la necesidad de herramientas de diagnóstico automatizadas y avanzadas se hace cada vez más presente.

Así, el presente planteamiento del problema se centra en la carencia de un algoritmo especializado apoyado en redes neuronales para la identificación automática del melanoma, constituyendo una barrera sustancial para la optimización del diagnóstico en la práctica clínica. La investigación propuesta busca llenar este vacío, ofreciendo una solución innovadora que contribuirá a mejorar la

eficacia y precisión del diagnóstico dermatológico, a la par que responde a la demanda creciente de herramientas tecnológicas avanzadas en el ámbito de la salud cutánea.

1.3. JUSTIFICACIÓN

Este trabajo se fundamenta en la necesidad de mejorar la eficacia y precisión en el diagnóstico del melanoma mediante la aplicación de tecnologías de aprendizaje profundo, específicamente, la creación e implementación de un algoritmo basado en redes neuronales. La diagnóstico clínica se enfrenta a desafíos sustanciales en la identificación temprana y exacta de este tipo de afectación a la piel como es el melanoma, destacando la urgencia de soluciones innovadoras que trasciendan las limitaciones de los métodos tradicionales.

En el contexto actual, las prácticas diagnósticas dermatológicas convencionales, presentan restricciones significativas en términos de objetividad y capacidad para abordar la creciente complejidad de las condiciones cutáneas. La implementación de algoritmos que ayuden a esta problemática representa un paradigma avanzado que promete superar estas limitaciones, capitalizando el poder del aprendizaje profundo y la capacidad de procesamiento de información inherente a las redes neuronales.

La relevancia académica de este proyecto radica en su contribución a la sinergia entre la ciencia de datos y la medicina, explorando aplicaciones específicas en el ámbito de la salud. El desarrollo y aplicación de un algoritmo especializado en la identificación automática del cáncer de la piel aportará conocimientos al campo, generando avances sustanciales en la mejora de la atención médica dermatológica.

Asimismo, la justificación encuentra respaldo en la falta de herramientas automatizadas efectivas en este contexto, y la consecuente necesidad de abordar dicha carencia mediante la implementación de metodologías de vanguardia.

1.4. OBJETIVOS

1.4.1. OBJETIVO GENERAL

Desarrollar un algoritmo basado en redes neuronales para la identificación automatizada y clasificación precisa del melanoma mediante el análisis de imágenes, con el propósito de mejorar la eficiencia y precisión en el diagnóstico médico.


1.4.2. OBJETIVOS ESPECÍFICOS

- Realizar una revisión exhaustiva de la literatura científica relacionada con la identificación de enfermedades dermatológicas mediante algoritmos basados en redes neuronales, con el fin de identificar enfoques y arquitecturas exitosas previamente implementadas.
- Recopilar y preparar un conjunto de datos diverso y representativo de imágenes del melanoma para el entrenamiento, validación y evaluación del modelo propuesto.
- Diseñar una arquitectura de red neuronal específicamente adaptada para la detección del melanoma, considerando la complejidad y variabilidad de las condiciones dermatológicas.
- Implementar y entrenar el algoritmo de redes neuronales utilizando técnicas avanzadas de aprendizaje profundo, ajustando los hiperparámetros para optimizar la precisión y generalización del modelo.
- Evaluar la eficacia del modelo desarrollado mediante pruebas exhaustivas con conjuntos de datos de validación y prueba, presentando de manera gráfica las diferentes métricas obtenidas.
- Analizar y contextualizar los hallazgos obtenidos, identificando posibles limitaciones y oportunidades para futuras mejoras en la implementación de algoritmos de identificación automática de enfermedades dermatológicas.

2. MARCO TEÓRICO Y CONCEPTUAL

El área de la salud es un campo de mucha información, sin embargo, en este apartado se centra en un órgano de suma importancia para el cuerpo humano. Según (Guilera et al., 2015) la piel es el órgano más extenso del cuerpo humano y ofrece protección a los diferentes órganos, músculos y huesos. Además, esta funciona como barrera protectora contra microorganismos, funciona como regulador de temperatura y es un órgano sensorial excepcional, este permite obtener sensaciones tales como: el tacto, el calor, la presión o el frío.

Ilustración 1. Capas de la piel



ADAM.

Nota. Adaptado de Capas de la piel [Fotografía], por Biblioteca Nacional de Medicina (EE. UU.), 2019, Medlineplus (https://medlineplus.gov/spanish/ency/esp_imagepages/8912.htm)

2.1. INTRODUCCIÓN AL DIAGNÓSTICO DERMATOLÓGICO

Una vez entendido el actor principal en esta investigación, esta se centra en el diagnóstico de la identificación del melanoma. Esta enfermedad es diagnosticada por personales de la salud con el método tradicional. Tal y como redacta (Saul, 2015) la exploración física de la dermatosis (toda afección de la piel recibe este nombre) requiere los mismos procedimientos del conocimiento general médico, pero en especial de la inspección y de la palpación.

Por ello, como bien sostiene (Pibernat, 1996) el procedimiento para diagnosticar enfermedades cutáneas como es el melanoma guarda similitudes con el proceso utilizado para identificar trastornos patológicos en otros órganos del cuerpo. La obtención de información se lleva a cabo mediante la recopilación de

antecedentes médicos, la evaluación clínica y, en ciertas ocasiones, pruebas complementarias. La evaluación clínica constituye el componente fundamental, abarcando la inspección de la piel. Según los hallazgos y las sospechas diagnósticas, se realiza una exploración adicional minuciosa y específica de otros sistemas u órganos. Por último, se llevan a cabo pruebas complementarias según las necesidades de orientación diagnóstica o para realizar un diagnóstico diferencial.

Ilustración 2. Inspección del paciente



Nota. Adaptado de La Piel del Espíritu [Fotografía], por Academia Española de Dermatología y Venereología, 2016, Fundación Piel Sana

Sin embargo, la inspección y la palpación pueden no ser los únicos métodos para determinar la denominada dermatosis, siendo así, el aprendizaje profundo juega un papel importante en este dominio, con ello nos permite inspeccionar de manera más rigurosa si existe o no dicha afección en la piel. Para (Guzmán Bucio y Vega Memije, 2023) en su artículo “Inteligencia artificial en Dermatología” explica los estudios que realizaron diversos investigadores siendo estos una revisión sistemática de los usos de inteligencia artificial para la clasificación automatizada del cáncer de piel, específicamente de los que se enfocaron en el melanoma.

En este artículo los investigadores revisaron 19 estudios, en 11 de ellos analizaron imágenes dermatoscopias, 6 imágenes clínicas y 2 imágenes histológicas. Se emplearon redes neuronales convolucionales como tecnología para analizar imágenes debido a su arquitectura especialmente diseñada para esta tarea. Principalmente, se utilizó el aprendizaje supervisado durante este proceso. (Guzmán Bucio y Vega Memije, 2023)

En los trabajos realizados, las redes neuronales convolucionales demostraron un desempeño significativamente superior o al menos comparable al de los clínicos o patólogos. Los hallazgos destacan una probable aplicación de la inteligencia artificial, sugiriendo que podría evolucionar hacia un sistema de asistencia complementario para apoyar tanto a médicos clínicos como a patólogos. (Guzmán Bucio y Vega Memije, 2023)

2.2. MELANOMA: CANCER DE LA PIEL

(High et al., 2012) argumenta que la dermatología es el campo de la medicina que se ocupa del estudio macroscópico de la piel, la mucosa adyacente (oral y genital) y sus anejos, mientras que la dermatopatología trata sobre el estudio microscópico de estas mismas estructuras. Estos dos campos están íntimamente ligados, son complementarios y se necesitan mutuamente.

Esta definición antes dada es clave para el entendimiento del melanoma, debido a que este tipo de cáncer se hace presente en la piel siendo este último objeto de estudio en la dermatología. En (Gaudy-Marqueste et al., 2015) define el melanoma como un tumor maligno desarrollado a costas de los melanocitos (célula de la piel y los ojos que produce y contiene un pigmento llamado melanina). Estudios realizados indican que existe una gran incidencia en todos los países desarrollados. Uno de los factores de riesgo importante es la exposición solar. Otros de los factores de riesgos reconocidos son los fototipos claros y de presencia en un gran número de venus.

Otra definición según (Fuentes-García y Ocampo-Candiani, 2010) sostiene que el melanoma cutáneo es un tipo de cáncer que se origina en células de la piel llamadas melanocitos, que pueden crecer de manera anormal y producir pigmento oscuro. Este cáncer es conocido por su capacidad para propagarse a otras partes del cuerpo. Inicialmente, puede aparecer como un lunar pigmentado en la piel, pero si no se trata a tiempo, puede crecer rápidamente y diseminarse a través del sistema linfático y la sangre, lo que puede llevar a una alta tasa de mortalidad.

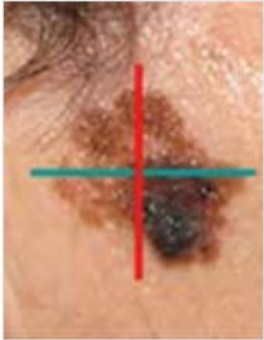

2.2.1. DIAGNÓSTICO CLÍNICO




Para obtener un éxito en el tratamiento del melanoma, lo más importante es la detección temprana de la patología. Gran parte de los melanomas pueden

identificarse clínicamente con un riguroso y detallado examen físico. Es necesario un buen lugar para efectuar el examen, donde se pueda permitir una buena iluminación la cual garantice el examen realizado con lupas y dermatoscopio. (Acosta et al., 2009)

Existen cambios muy sugestivos de una lesión sospechosa estos normalmente se presentan en un periodo de meses; cuando los cambios se manifiestan en días o semanas es más probable que se trate de condiciones inflamatorias. Los cambios iniciales comúnmente observados incluyen un aumento considerable del tamaño de la lesión y cambios súbitos en la coloración. Además de estos cambios también pueden venir acompañados de aumento de altura, el prurito y la presencia de ulceración o sangrado, comúnmente estos cambios se presentan en lesiones más avanzadas. Para diagnosticar clínicamente el melanoma se ha implementado el sistema ABCDE como se observa en la tabla 1. Cualquier cambio notable en las lesiones cutáneas debería levantar sospechas en un paciente, esto se debe a que algunos melanomas no suelen presentar cambios típicos especificados en el ABCDE detallados en la tabla #1. Esto conlleva a que muchas veces los melanomas se diagnostiquen erróneamente como cualquier otra lesión distinta al melanoma. (Acosta et al., 2009)

Tabla 1. Criterios ABCDE para el diagnóstico de melanoma

A	Asimetría	
B	Bordes irregulares	

C	Color (variación)	
D	Diámetro de superior de 6 mm	
E	Elevación Evolución	

Nota. Acosta, Á. E., Fierro, E., Velásquez, V. E., & Rueda, X. (2009). Melanoma: patogénesis, clínica e histopatología. [Tabla del ABCDE para diagnóstico clínico del melanoma]. Revista de la Asociación Colombiana de Dermatología y Cirugía Dermatológica, 17(2), 87-108

2.3. FUNDAMENTOS DE INTELIGENCIA ARTIFICIAL

Es regular leer y escuchar en diferentes medios información sobre inteligencia artificial, aprendizaje automático, redes neuronales, entre otros términos del área. A partir de aquí, se procederá a definir ciertos conceptos o criterios que se tengan en cuenta para el entendimiento de la presente investigación.

2.3.1. INTELIGENCIA ARTIFICIAL

(Beunza Nuin et al., 2020) establece en su libro “Manual práctico de inteligencia artificial en entornos sanitarios” la Inteligencia artificial o IA es una tecnología desarrollada capaz de imitar las funciones cognitivas del ser humano.

Una idea similar puede encontrarse en (Rouhiainen, ¿Qué es exactamente la inteligencia artificial?, 2018) donde explica la complejidad de un tema como es la Inteligencia Artificial. El autor define a la IA como “la habilidad de los ordenadores para hacer actividades que normalmente requieren inteligencia humana”. Sintetizando, se puede interpretar a la IA como el potencial que tiene las máquinas para hacer uso de algoritmos, y obtener información de los datos y tomar decisiones en base a los resultados como si de un ser humano se tratara.

Para (Beunza Nuin et al., 2020) hay 3 diferentes tipos de inteligencia artificial.

IA estrecha o débil (ANI, Artificial narrow Intelligence). Este tipo de Inteligencia artificial tiene una tarea única y concreta. La mayor parte de los algoritmos disponibles que están desarrollados con esta IA pertenecen al área de la salud. (Beunza Nuin et al., 2020)

IA general (AGI, Artificial general Intelligence). Compara la función de la inteligencia artificial con las habilidades humanas. La AGI es un campo emergente, en pleno desarrollo, con gran potencial a futuro, pero todavía lejos de la práctica sanitaria presente. (Beunza Nuin et al., 2020)

Super IA (ASI, Artificial super Intelligence). Es un campo futurible en el que las aplicaciones de inteligencia artificial superarían la capacidad humana en todos los campos, incluidos la expresión artística, la toma de decisiones y la gestión de emociones interpersonales. (Beunza Nuin et al., 2020)

2.3.2. APLICACIONES DE LA IA EN LA MEDICINA

Para (Ávila-Tomás et al., 2021) recientemente la IA comienza a incorporarse a la medicina en pro de mejorar la atención al paciente haciendo que se aceleren los procesos y se obtenga una alta precisión en los diagnósticos médicos. Muchos de los procesos como: imágenes radiológicas, preparaciones de anatomía patológica e historiales médicos se están llevando a cabo mediante aprendizaje automático.

ASISTENCIAL

- **Prevención de enfermedades y diagnóstico precoz:** Se han creado algoritmos que pueden ayudar en la prevención del cáncer de cérvix mediante el uso de software de aprendizaje automático para detectar el virus del papiloma humano (VPH). (Ávila-Tomás et al., 2021)
- **Diagnóstico:** Existen software de apoyo y ayuda al diagnóstico como MYCIN/MYCIN II para enfermedades infecciosas, CASNET para oftalmológica, PIP para enfermedades renales o IA/RHEUM para enfermedades reumatológicas. (Ávila-Tomás et al., 2021)
- **Seguimiento, soporte y monitorización:** En la actualidad, se están desarrollando asistentes robóticos con inteligencia artificial (IA) para

diversas funciones en el ámbito de la salud, incluyendo proporcionar información, facilitar la comunicación y acompañar a las personas. (Ávila-Tomás et al., 2021)

DOCENCIA Y FORMACIÓN CONTINUADA

- Desarrollo de entornos virtuales de entrenamiento o aprendizaje que replican intervenciones reales sin ningún riesgo. Su utilidad radica en la simulación de cirugías estableciendo una capa de la IA como un entrenador docente que interactúa con un estudiante a través de la realidad virtual y/o aumentada. (Ávila-Tomás et al., 2021)
- Evaluación del progreso del estudiante. Se contempla ajustes de prueba sucesivas a los logros alcanzados. (Ávila-Tomás et al., 2021)
- Establecer criterios objetivos, basados en medidas tangibles, por parte del evaluador, para definir los niveles de habilidad de los estudiantes. (Ávila-Tomás et al., 2021)

INVESTIGACIÓN

- Actualmente, se están desarrollando numerosos estudios para indagar la efectividad de la inteligencia artificial (IA) en el campo de la salud. Grandes empresas de software están desarrollando alianzas estratégicas con universidades para implementar terminales especializados para monitorear y gestionar diversas enfermedades y procesos médicos. (Ávila-Tomás et al., 2021)
- La IA beneficia notablemente a muchas investigaciones biomédicas al reducir costos y simplificar la recolección y manejo de datos mediante modelos semánticos y relaciones entre variables, ofreciendo una perspectiva diferente a la estadística tradicional. (Ávila-Tomás et al., 2021)

2.3.3. APRENDIZAJE AUTOMÁTICO

(Moreno et al., 1994) describe el aprendizaje automático como un tipo de aprendizaje el cual consiste en reconocer una situación problemática y reaccionar usando la estrategia aprendida. También explica que el aprendizaje automático también es denominado aprendizaje artificial, la cual es un área muy desarrollada de la IA.

A continuación, se procede a explicar las diferentes clases de aprendizaje automático que existe:

2.3.3.1. APRENDIZAJE SUPERVISADO.

En este tipo de aprendizaje, se entrenan algoritmos de Machine Learning otorgándoles características y etiquetas, es decir, son algoritmos etiquetados. Siendo así, un algoritmo puede predecir en base al conocimiento de ciertos tipos de características. (Sandoval Serrano, 2018)

2.3.3.2. APRENDIZAJE NO SUPERVISADO.

A diferencia del aprendizaje supervisado, en los algoritmos de aprendizaje no supervisado se les otorga características, nunca las etiquetas. Dichos algoritmos utilizan las características para clasificar a qué grupo pertenece cierto dato. (Sandoval Serrano, 2018)

2.3.3.3. APRENDIZAJE POR REFUERZO.

En estos algoritmos se aprende en base a la experiencia. Es decir, se debe proveer al algoritmo “un refuerzo positivo” cada vez que este acierta. Esta forma de aprendizaje es muy comparada con la de los perros cuando se les ofrece recompensas por alguna habilidad aprendida. (Rouhiainen, Aprendizaje automático, 2018)

2.3.4. APRENDIZAJE PROFUNDO

El aprendizaje profundo, en inglés Deep Learning. Se trata de un subcampo presente en el aprendizaje automático o Machine Learning. Esta es una de las aplicaciones más poderosas y de mayor crecimiento de la IA. (Rouhiainen, Aprendizaje profundo, 2018)

El Deep Learning ofrece a los modelos computacionales aprender representaciones de datos con varios niveles de abstracción. Los algoritmos de Deep Learning han mejorado de manera exponencial en los campos como reconocimiento de habla, reconocimiento visual, detección de objetos, entre otros. El aprendizaje profundo revela estructuras alojadas en grandes volúmenes de datos haciendo uso de diferentes algoritmos de propagación que indican como una máquina puede cambiar sus parámetros internos los cuales se utilizan para calcular representaciones en cada capa de manera sucesiva. (LeCun et al., 2015)

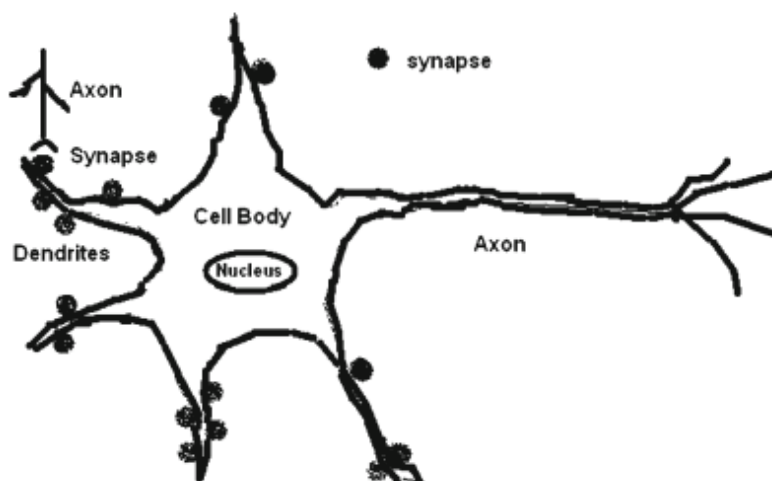
2.3.5. REDES NEURONALES

(Shrestha y Mahmood, 2019) definen en su artículo “Review of Deep Learning Algorithms and Architectures” a las Redes Neuronales como una técnica de Machine Learning la cual es inspirada en el sistema nervioso central de los humanos y sobre todo en la estructura cerebral. Este tipo de estructura contiene unidades de procesamiento distribuidas en capas de entrada, varias capas ocultas y capas de salida. Los nodos presentes en cada capa están interconectados de manera adyacente. De esta manera, las redes neuronales tienen aplicaciones diversas, abarcando desde el reconocimiento de patrones y la clasificación hasta la reducción de la dimensionalidad, la visión por computadora, el procesamiento del lenguaje natural (PLN), la regresión y el análisis predictivo, entre otros usos.

2.3.5.1. REDES NEURONALES ARTIFICIALES

Las Redes Neuronales Artificiales están inspiradas en las arquitecturas de las neuronas biológicas, tales como las del cerebro humano. Las neuronas están interrelacionadas y conforman en su gran mayoría el cerebro humano. Cada una de estas neuronas realiza una tarea sencilla, no obstante, cuando existe una red de neurona está en funcionamiento puede realizar tareas altamente complejas. (Zou et al., 2008)

Ilustración 3. Esquema de una neurona biológica



Nota. Zou, J., Han, Y. & Sung-Sau S. (2008). *Overview of Artificial Neural Networks*. Livingstone, D.J. (eds) [Imagen de neurona biológica]. Recuperado de https://doi.org/10.1007/978-1-60327-101-1_2


La red neuronal artificial tiene como modelo una red biológica, de la cual se habló previamente. De igual manera que esta red neuronal biológica, la red neuronal artificial o por sus abreviaturas RNA es una interconexión entre los diferentes nodos y análogos a las neuronas. Dentro de cada red neuronal se establecen tres componentes críticos: el carácter de los nodos, la topología de la red y las reglas de aprendizaje. En primer lugar, el carácter del nodo establece como realizar el procesamiento de las señales. Por consiguiente, la topología de la red determina la estructura y la conexión de dichos nodos. Y, por último, las reglas de aprendizaje forman la inicialización y ajustes de los pesos en cada uno de estos nodos. (Zou et al., 2008)

2.3.5.2. REDES NEURONALES CONVOLUCIONALES

Una red neuronal convolucional (CNN) en la actualidad es una de las redes más significativas en el campo del Deep Learning. La CNN es un tipo de red neuronal feedforward la cual es capaz de identificar peculiaridades de los datos con estructuras de convolución. En contraste de otros métodos, la CNN no requiere obtener dichas características de forma manual. La arquitectura de la CNN tiene su inspiración en una percepción visual. Una neurona biológica se equipa con una neurona artificial en el contexto de las redes neuronales convolucionales (CNN), donde los núcleos representan receptores que detectan varias características. Las funciones de activación imitan la transmisión selectiva de señales neuronales sólo cuando superan cierto umbral. En comparación de las redes totalmente conectadas

FC de la ilustración 4 las CNN posee múltiples ventajas: 1) conexiones locales: las neuronas son conectadas a un pequeño número de neuronas lo cual incrementa la eficacia al reducir los parámetros y acelerar la convergencia. 2) Compartir pesos: Los grupos de conexiones pueden compartir pesos similares, esto ayuda a la reducción de los parámetros. 3) Reducción de la dimensión de muestreo: la capa de agrupación se beneficia del principio de correlación local de imágenes para muestreo de imagen. (Zewen et al., 2022)

Ilustración 4. Esquema de las capas CNN y FC



Nota. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects," in *IEEE* vol. 33 [Imagen] Recuperado de: <https://doi.org/10.1109/TNNLS.2021.3084827>

Existen varias arquitecturas de redes neuronales convolucionales, entre ellas se tiene:

ResNet: La unidad modular dentro de la arquitectura de red residual generalizada se compone de un bloque residual generalizado que incluye estados paralelos para un flujo residual, que posee conexiones de atajo de identidad y guarda similitudes con la estructura de un bloque residual de la ResNet original que tiene una única capa convolucional, y un flujo transitorio, que consiste en una capa convolucional convencional. Además, dos conjuntos extra de filtros convolucionales en cada bloque facilitan la transferencia de información entre los flujos. (Targ et al., 2016)

EfficientNet: EfficientNet es un algoritmo de aprendizaje profundo diseñado para alcanzar un rendimiento líder en una variedad de tareas de clasificación de imágenes, al tiempo que reduce la complejidad computacional. Su arquitectura se fundamenta en el enfoque de las redes neuronales convolucionales (CNN) y consta de una secuencia de capas convolucionales, seguidas de capas de agrupación y capas totalmente conectadas. Utiliza una combinación de convoluciones separables en


profundidad y bloques de cuello de botella invertidos para mejorar la eficiencia sin sacrificar precisión. (Samis Anwar, 2023)

Inception (GoogLeNet): Google introdujo Inception en un concurso de reconocimiento visual a gran escala, siendo este el mejor modelo en rendimiento denominado GoogLeNet. La estructura interna se compone de un núcleo el cual se amplió para ofrecer varias salidas a distribuciones de correlación basándose en la idea de que la salida de la red neuronal tiene una eficiencia óptima. En el interior de cada capa, las capas convolucionales tienen diversa información espacial de los datos de entrada y los resultados se combinan en un solo conjunto de datos. (Kim et al., 2019)

2.3.5.3. REDES NEURONALES RECURRENTE

Las redes neuronales recurrentes (RNN) es una arquitectura de red neuronal la cual tiene como característica principal la detección de patrones secuenciales de datos. Dichos datos pueden ser de distintos tipos tales como: escritura manuscrita, genomas, textos o series temporales numéricas. No obstante, el uso de esta arquitectura de red no solo tiene esta utilidad, sino también son aplicables a imágenes, para ello las imágenes deben descomponerse en una serie de parches simulando una secuencia. Por otra parte, las RNN tiene mayor aplicación en el modelado de lenguaje, la generación de texto, el reconocimiento por voz y la creación de nuevas descripciones de imágenes, así también como en el etiquetado de video. La principal diferencia de las RNN en comparación a las Redes Neuronales Feed-Forward es su forma de transmisión de información a través de toda la red. Mientras que las Redes Feed-Forward pasan dicha información a la red sin la utilización de ciclos, las RNN realizan múltiples iteraciones donde la información vuelve a sí misma, como se visualiza en la ilustración 5. Esto es beneficioso ya que permite la ampliación de funcionalidades de las CNN. (Schmidt, 2019)

Ilustración 5. Diferencia entre Redes Recurrentes y Redes Feed-Forward



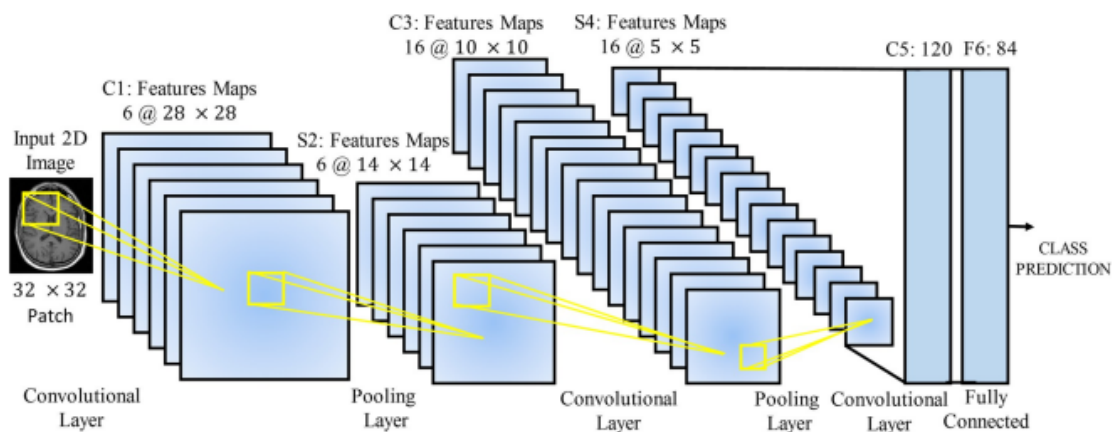
Nota. Aplanet (2024). Fundamentos del Deep Learning. [Imagen de Redes Neuronal Feed-Forward y Redes Neuronal Recurrente]. Recuperado de: <https://aiplanet.com>

2.4. APLICACIONES DE REDES NEURONALES EN MEDICINA

- (Baxt, 1995) en su artículo “Applications of artificial neural networks to clinical medicine” expone el argumento de un hombre de 51 años que ingresa a la sala de emergencias con una dolencia torácica. Este paciente niega antecedentes personales o familiares significativos de cardiopatía, por ende, no presenta ningún factor de riesgo cardiaco. Se le realiza un electrocardiograma (ECG) al paciente donde revela un leve aplanamiento de la onda T. La información obtenida del electrocardiograma es introducida a un sistema de línea de gestión y registro médico. El sistema en cuestión tiene integrada una red neuronal entrenada para identificar infartos agudos en el miocardio. La red tiene como finalidad analizar la información y presentarla por pantalla si el paciente ha tenido un infarto en el miocardio. El médico utiliza esta información para combinar con su diagnóstico para luego mantener al paciente en observación. El escenario propuesto está basado en una red real, siendo esta una de las primeras aplicaciones de redes neuronales artificiales en la medicina clínica. Actualmente, se ha revelado que esta red es más precisa incluso que los médicos a la hora de identificar infartos agudos en el miocardio.
- (Anwar et al., 2018) en su artículo “Medical Image Analysis using Convolutional Neural Networks: A Review” expone la existencia de una gran variedad de modalidades de imágenes médicas que son utilizadas con fines de pronósticos y diagnósticos, estas en su mayoría tienen aspectos similares. La problemática se resuelve mediante el uso del aprendizaje profundo o Deep Learning, donde la arquitectura admite aprender información difícil. En la

ilustración 6 se muestra una arquitectura de CNN denominada LeNet-5 la cual es utilizada para la clasificación de imágenes médicas con N clases que permiten un parche de 32x32 de una imagen médica 2D. Esta red tiene capas convolucionales de máxima agrupación y totalmente conectadas. Cada una de estas capas crea un mapa de características de varios tamaños y las capas de agrupación reducen el tamaño de los mapas que se transfieren a las siguientes capas. Una vez realizado todo el proceso, se obtiene una predicción de clase requerida donde la etapa de entrenamiento de la red promete que se aprendan los mejores pesos.

Ilustración 6. Arquitectura típica de una Red Neuronal Convolutiva para la clasificación de imágenes médicas



Nota. Anwar, S.M., Majid, M., Qayyum, A. et al. Medical Image Analysis using Convolutional Neural Networks: A Review. J Med Syst 42, 226 (2018). [Imagen de capas de CNN] <https://doi.org/10.1007/s10916-018-1088-1>

- A partir de la pandemia del COVID-19 los estudios acerca del área se hicieron más presente y las redes neuronales convolucionales realizaron un importante avance en ello. (Marques et al., 2020) propone en su investigación desarrollar un sistema de apoyo a la toma de decisiones médicas usando CNN en la arquitectura EfficientNet. Esta arquitectura puede usarse para el aprendizaje por transferencia, dicho aprendizaje es más eficiente que gran parte de sus predecesores como VGG, GoogleNet y Residual Network. El modelo EfficientNet tiene 8 modelos, de este cada número de modelo hace referencia a variantes con parámetros distintos y de mayor precisión. Esta arquitectura utiliza el aprendizaje por transferencia esto ayuda a que el modelo ahorre tiempo y potencia al momento de realizar los

cálculos. En la investigación describe dos experimentos principales que emplean diversos conjuntos de datos para pruebas y validación, con el propósito de evitar el sobreajuste. Primero, se muestran los resultados de la clasificación binaria que utiliza imágenes de pacientes con COVID-19 y sin la enfermedad. Luego, los resultados de la clasificación multiclase son analizados, estos incluyen imágenes de pacientes con COVID-19, neumonía y sin enfermedades. El código fuente se encuentra disponible en este documento como archivos adicionales.

- En radiología también existe un uso de redes neuronales, tal y como explica (Yamashita et al., 2018) en su artículo “Convolutional neural networks: an overview and application in radiology”. Aquí presenta ciertas de las aplicaciones recientes en radiología. En el ámbito del análisis de imágenes médicas, la clasificación del Deep Learning se utiliza en lesiones presentadas mediante imágenes médicas y se clasifican en dos o más clases. En este contexto, el aprendizaje profundo se utiliza para la clasificación de nódulos pulmonares en imágenes de tomografías computarizadas (TC) ya sea benignos o malignos. Para la clasificación de nódulos pulmonares se hace uso de imágenes de TC donde cada imagen debe pertenecer a una etiqueta (benigno o canceroso) como dato de entrenamiento. En el mismo artículo (Yamashita et al., 2018) sostiene que “la segmentación de órganos o estructuras anatómicas es esencial en el procesamiento de imágenes médicas”. Esta se utiliza para analizar datos médicos tales como el volumen de los órganos y la forma de los órganos, y para sistemas de diagnóstico asistido por computadora (CAD). La segmentación, a menudo llevada a cabo manualmente por radiólogos o personal especializado, es un proceso laborioso. Pero la Convolutional Neural Network (CNN) también puede emplearse para esta tarea, ofreciendo una alternativa automatizada y eficiente.
- Según (Srivastava et al., 2022) la detección del COVID-19 mediante IA y el Diagnóstico Asistido por Ordenador ha sido puntos clave de varios estudios. Las redes neuronales profundas, es decir, las redes

neuronales estudiadas en Deep Learning contienen cientos de pesos los cuales son denominadas “cajas negras” ya que es difícil entender ese comportamiento, a pesar de que tanto la estructura del modelo como los pesos del modelo son perceptibles. En dicho banco de datos, las distintas redes neuronales tienen un funcionamiento distinto. Por ello, no se tiene un modelo único, sino que se puede evaluar mediante la combinación de varios modelos. Aunque incluir varios modelos no siempre es factible, los autores determinaron que la puntuación del conjunto de volantes de los falsificadores individuales basándose en el teorema del Jurado de Condorcet. Los autores mostraron que, al combinar N clasificadores en redes neuronales, se cumple el teorema. Utilizando el CJT, demostraron que la inclusión de un modelo en el conjunto de votantes mejoraría la precisión del voto mayoritario si dicho modelo es más preciso que los demás.

3. DESARROLLO DE UN ALGORITMO CON REDES NEURONALES PARA LA IDENTIFICACIÓN DEL MELANOMA

En este apartado se describen las técnicas y procedimientos utilizados para llevar a cabo la clasificación de imágenes de melanoma mediante redes neuronales convolucionales (CNN). La metodología seguida en este estudio abarca desde la recopilación y preprocesamiento de los datos, hasta el diseño y entrenamiento de la red neuronal. De esta forma, se busca garantizar que el proceso sea reproducible y transparente, proporcionando detalles específicos sobre cada etapa del desarrollo del modelo.

La elección de CNN para este proyecto se basa en su demostrado rendimiento en tareas de reconocimiento de patrones en imágenes, específicamente en el ámbito de la medicina donde la precisión es crucial. La estructura del modelo se construyó siguiendo prácticas recomendadas y se optimizó para maximizar su capacidad de generalización, minimizando tanto la pérdida de entrenamiento como el sobreajuste.

3.1. REVISIÓN DE LA LITERATURA

Se llevó a cabo una revisión detallada de estudios previos sobre la clasificación de imágenes de melanoma utilizando técnicas de aprendizaje profundo, específicamente redes neuronales convolucionales (CNN). La revisión de literatura tiene como objetivo identificar las metodologías más efectivas y los desafíos comunes en este campo, así como proporcionar una base sólida para las decisiones metodológicas tomadas en este estudio.

3.1.1. INTRODUCCIÓN A LA CLASIFICACIÓN DE IMÁGENES MÉDICAS

La clasificación de imágenes médicas ha sido un área de investigación activa debido a su potencial para mejorar el diagnóstico y el tratamiento de enfermedades. En particular, la identificación del cáncer de piel, como el melanoma, a partir de imágenes dermatoscópicas ha mostrado resultados prometedores mediante el uso de CNN. Estas redes han demostrado un alto rendimiento en tareas de

reconocimiento de patrones complejos debido a su capacidad para aprender características jerárquicas a partir de los datos de entrada.

3.1.2. ESTUDIOS PREVIOS EN CLASIFICACIÓN DE MELANOMA

Numerosos estudios han explorado el uso de CNN para la detección y clasificación de melanoma. En (Sherif, 2019) se presentan métodos basados en aprendizaje profundo para abordar los problemas en el análisis de lesiones cutáneas mediante el uso de imágenes dermatoscópicas que contienen tumores de la piel. Los modelos propuestos se entrenan y evalúan utilizando conjuntos de datos estándar del Desafío ISIC 2018 de la International Skin Imaging Collaboration. El método propuesto logra una precisión del 96,67% en el conjunto de validación. Por otro lado, (Shawon et al., 2021) presenta un sistema de diagnóstico asistido por computadora para el cáncer de piel, basado en redes neuronales convolucionales (CNN). El sistema consta de cinco etapas: adquisición de imágenes, preprocesamiento, segmentación, extracción y clasificación de características. Se utilizó opaco para eliminar ruido y filtro mediano para suavizar imágenes. La segmentación se realizó con el algoritmo k-means. Las imágenes segmentadas se introdujeron en el modelo CNN para la extracción y clasificación de características. El sistema logró una precisión del 80,47% en la clasificación de cánceres de piel benignos y melanoma en imágenes dermatoscópicas. Se comparó con otros modelos como ANN, KNN y bosque aleatorio en la colección de datos de prueba 'ISIC Challenge 2016', mostrando superioridad en precisión.

3.1.3. MÉTODO DE PROCESAMIENTO Y AUMENTO DE DATOS

El preprocesamiento y el aumento de datos son pasos cruciales para optimizar el rendimiento de los modelos de CNN. Técnicas como la normalización de imágenes, el ajuste de contraste y brillo, y el aumento de datos mediante rotaciones, traslaciones y zoom han sido ampliamente utilizadas. Por ejemplo, en (Shawon et al., 2021) se implementó un algoritmo DullRazor para eliminar los vellos y suavizar las imágenes.

3.1.4. ARQUITECTURA DE REDES NEURONALES

Diversas arquitecturas de CNN han sido propuestas para la labor de clasificación de imágenes de melanoma. Arquitecturas populares como GoogLeNet, ResNet y EfficientNet han sido adaptadas y comparadas en términos de precisión y eficiencia computacional. En (Banerjee et al., 2020) describe un algoritmo llamado 'You Only Look Once (YOLO)', basado en aprendizaje profundo, que utiliza CNN profundas para la detección de melanoma en imágenes dermatoscópicas y digitales. Este enfoque proporciona resultados más rápidos y precisos que los obtenidos mediante CNN convencionales.

3.2. RECOPIACIÓN Y PROCESAMIENTO DE DATOS.


3.2.1. RECOPIACIÓN DE DATOS

Los datos utilizados en este estudio fueron obtenidos de la plataforma Kaggle, específicamente del dataset "Melanoma", disponible públicamente en esta comunidad en línea para científicos de datos. Es imprescindible acentuar que para este trabajo se utilizó una muestra representativa del dataset, seleccionada de manera aleatoria para asegurar la diversidad y representatividad de los datos en relación con el tema de investigación. La elección de esta porción del dataset se basó en criterios de relevancia y disponibilidad de datos para el entrenamiento y validación del modelo propuesto.

3.2.2. DESCRIPCIÓN DE LOS DATOS

El dataset utilizado en este estudio se organiza en tres directorios principales: entrenamiento (train_sep), validación (valid), y prueba (test). Cada uno de estos directorios están divididos en dos subdirectorios correspondientes a las clases de diagnóstico: Melanoma y NotMelanoma.

Ilustración 7. Imágenes de Melanoma y NotMelanoma
Imágenes de Melanoma y notMelanoma



Nota: Fuente: Elaboración propia

A continuación, se detalla la cantidad de imágenes presentes en cada directorio:

1. Conjunto de Entrenamiento (train_sep):

- **Melanoma:** La carpeta de entrenamiento contiene un total de 1008 imágenes clasificadas como Melanoma. Estas imágenes representan casos confirmados de melanoma y se utilizan para entrenar el modelo para identificar características distintivas de esta condición.
- **NotMelanoma:** En la subcarpeta NotMelanoma, se encuentran 1008 imágenes que representan casos benignos. Estas imágenes se emplean para enseñar al modelo a diferenciar entre melanoma y otras afecciones cutáneas no malignas.

En total, el conjunto de entrenamiento cuenta con 2016 imágenes, distribuidas equitativamente entre las dos clases, asegurando un balance adecuado que es crucial para un entrenamiento efectivo del modelo.

2. Conjunto de Validación (valid):

- **Melanoma:** La carpeta de validación contiene 336 imágenes de Melanoma. Estas imágenes se utilizan durante el proceso de entrenamiento para validar la eficiencia del modelo y ajustar hiperparámetros, ayudando a prevenir el sobreajuste.

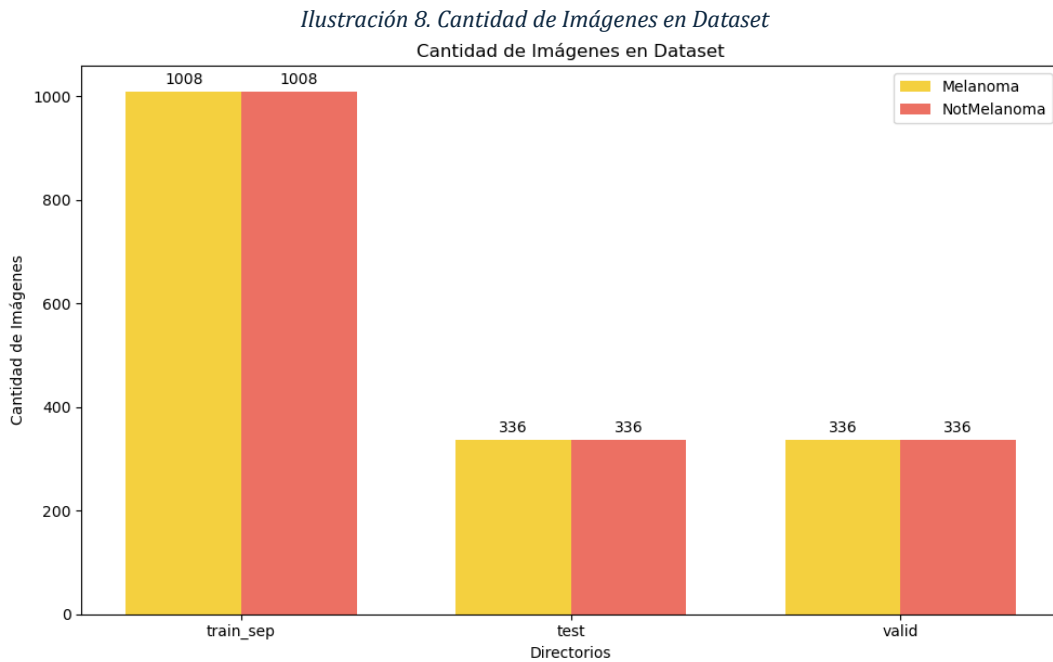
- **NotMelanoma:** De igual manera, hay 336 imágenes de “NotMelanoma” en la subcarpeta correspondiente. Estas imágenes permiten una evaluación intermedia de la capacidad del modelo para generalizar datos no vistos durante el entrenamiento.

El conjunto de validación incluye un total de 672 imágenes, distribuidas equitativamente entre las dos clases.

3. Conjunto de Prueba (test):

- **Melanoma:** La carpeta de prueba cuenta con 336 imágenes clasificadas como Melanoma. Estas imágenes se utilizan para la evaluación final del modelo, proporcionando una medida objetiva de su desempeño en la clasificación de nuevos casos.
- **NotMelanoma:** En la subcarpeta “NotMelanoma”, también se encuentran 336 imágenes. Este conjunto permite evaluar la precisión del algoritmo en la identificación de casos benignos en un entorno controlado.

El dataset de prueba contiene un total de 672 imágenes, distribuidas equitativamente entre las dos clases.



Nota. Fuente: Elaboración propia

La distribución equilibrada de imágenes en cada conjunto es crucial para el desarrollo de un modelo robusto y confiable. Asegura que el modelo tenga

suficientes ejemplos de ambas clases para aprender las características distintivas de cada una, valida su rendimiento de manera continua y evalúa su capacidad para generalizar a nuevos datos de manera precisa.

3.2.3. PROCESAMIENTO DE DATOS

El procesamiento de datos es un paso crucial para preparar las imágenes de entrada antes de entrenar el modelo de clasificación. En este estudio, se implementaron varias técnicas de preprocesamiento para optimizar la calidad de las imágenes y facilitar la extracción de características relevantes.

Uno de los desafíos comunes en la clasificación de imágenes dermatológicas es la presencia de vellos que pueden obstruir la visibilidad de las características importantes de la piel. Para mitigar este problema, se utilizó el algoritmo DullRazor, el cual está diseñado específicamente para suavizar las imágenes y eliminar los vellos. Este algoritmo actúa identificando y removiendo las áreas de las imágenes que contienen vellos, reemplazándolas con información interpolada de los píxeles circundantes. Este proceso mejora significativamente la claridad de las imágenes, facilitando la tarea de detección y clasificación de características melanocíticas. (Lee et al., 1997)

Para muestra, a continuación, se explica paso a paso el proceso que realiza el algoritmo DullRazor para eliminar los vellos de las imágenes. Por ello, se tiene una imagen sin procesar extraída del dataset antes descrito.

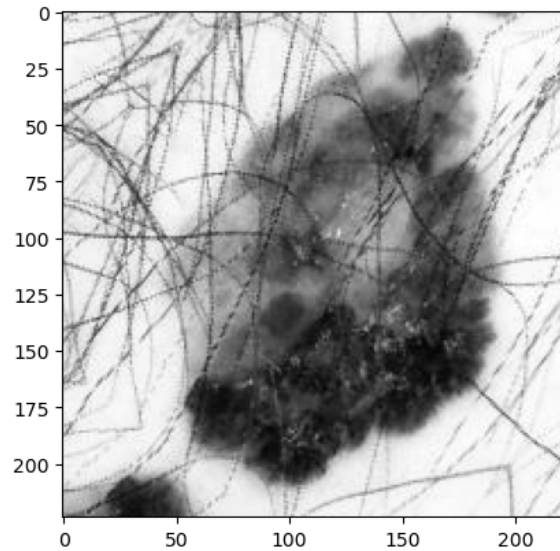
Ilustración 9. Imagen de Melanoma



Nota. Fuente: Dataset Melanoma Kaggle

El algoritmo DullRazor comienza convirtiendo la imagen original en formato RGB a escala de grises. Este paso simplifica el procesamiento al trabajar con una única capa de intensidad, lo cual es efectivo para la detección de características sutiles como el vello.

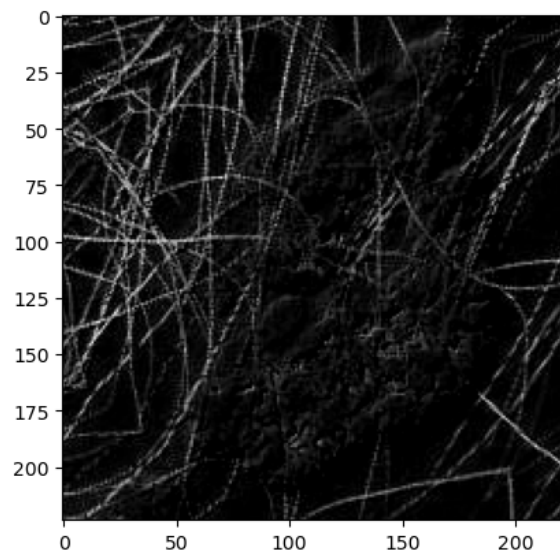
Ilustración 10. Imagen en escala de grises



Nota. Fuente: elaboración propia

Luego de esto, se aplica una operación morfológica denominada BlackHat utilizada para resaltar estructuras oscuras sobre fondos claros en una imagen. Se emplea un kernel estructurante rectangular para identificar y resaltar el vello, que se presenta como características oscuras en imágenes médicas. Para este procesamiento se está utilizando un kernel de 3x3, sin que este resulte ser muy agresivo para la imagen.

Ilustración 11. Aplicación de Blackhat




Nota. Fuente: Elaboración propia

Posteriormente, se aplica una técnica de umbralización sobre la imagen resultante del Blackhat. (Cortés Osorio et al., 2011) explica la umbralización como una técnica de segmentación sencilla y eficaz que divide los píxeles de una imagen en escala de grises en dos categorías a partir de una ventana o borde umbral.

Esta etapa segmenta la imagen en dos regiones binarias: una que identifica áreas con vello (marcadas en blanco) y otra que identifica áreas sin vello (marcadas en negro). El umbral determina el valor mínimo de intensidad para considerar un píxel como parte del vello.


Ilustración 12. Técnica de umbralización



Nota. Fuente: Elaboración propia

Luego de realizar la umbralización y determinar las zonas con vello, se realiza un proceso para eliminar visualmente el vello detectado en la imagen original. Utilizando la máscara binaria generada por la umbralización, el algoritmo rellena las áreas marcadas (vello) utilizando información de los píxeles circundantes. Esto permite una integración suave y natural de las áreas con el resto de la imagen.

Ilustración 13. Imagen en colores BGR



Nota. Fuente: Elaboración propia

Una vez realizado todo este proceso, se obtiene una imagen la cual fue suavizada y eliminado el vello. Sin embargo, la imagen resultante está en una matriz de colores BGR y se debe pasar a imágenes RGB para su correcta visualización. Siendo así el resultado obtenido mostrado a continuación donde podemos observar en el lateral izquierdo la imagen original y del lado izquierdo la imagen procesada por el algoritmo DullRazor.

Ilustración 14. Aplicación del algoritmo DullRazor



Nota. Fuente: Elaboración propia


Como parte del procesamiento de datos, una vez que se aplicó el algoritmo DullRazor las imágenes resultantes fueron pasadas por un conjunto de transformaciones para mejorar la calidad de la información optimizándola para su visualización y análisis. Las imágenes fueron redimensionadas a un tamaño

uniforme de 224x224 píxeles. Este tamaño fue seleccionado debido a su compatibilidad con las arquitecturas de redes neuronales convolucionales preentrenadas, que requieren un tamaño de entrada específico. El redimensionamiento asegura que las imágenes mantienen una relación de aspecto adecuada y que las características espaciales consideradas importantes no se den por obviadas durante el proceso.

Inmediatamente se aplica una técnica de mejora de la nitidez conocida como "Unsharp Masking" que según (Laine y Huda, 2000): una máscara de desenfoque es una técnica que implica crear una imagen ligeramente desenfocada de un negativo original en un nuevo fragmento de película.

Puesto que se crea una versión desenfocada de la imagen original usando un filtro Gaussiano. A partir de aquí, la imagen original se mezcla con esta versión desenfocada.

Ilustración 15. Máscara de desenfoque




Nota. Fuente: Elaboración propia

La aplicación de esta técnica de mejora de nitidez en el procesamiento de imágenes ofrece varios beneficios clave, especialmente en el ámbito médico y la visión por computadora. Esta técnica resalta bordes y detalles finos, mejorando la percepción visual y la claridad de la imagen, lo que facilita la identificación precisa de estructuras anatómicas y anomalías. Además, incrementa el contraste local sin perder la información global de la imagen, permitiendo una interpretación más

detallada y precisa. El resultado que se obtiene es una imagen en la cual se puede apreciar de una forma óptima todas las características de la lesión.

Ilustración 16. Imágenes procesadas
Imágenes de Melanoma y notMelanoma



Nota. Fuente: Elaboración propia

Como último paso en la preparación de los datos, se realizó un proceso de aumentación de datos con el fin de ayudar en la convergencia de la red neuronal. Siendo así, se realiza una normalización de datos. Dado que las imágenes generalmente están representadas con valores de píxeles en el rango $[0, 255]$, la normalización es una práctica común en redes neuronales para convertir estos valores a un rango $[0, 1]$ lo cual es favorable en términos de consistencia en el procesamiento de datos, mejorando el rendimiento y la estabilidad del entrenamiento y evaluación del modelo de red neuronal.

3.3. DISEÑO DE LA ARQUITECTURA DE RED NEURONAL

A partir de aquí se explicará de manera detallada el proceso de construcción del algoritmo de red neuronal. El tipo de modelo de red neuronal empleada fue la red neuronal convolucional CNN, puesto que han demostrado ser herramientas poderosas en el Deep learning o aprendizaje profundo, específicamente en áreas relacionadas con la visión por computadora como reconocimiento de imágenes y estas por su gran capacidad de procesamiento son beneficiarias de un sinnúmero de filtros para su recolección de características.

El uso de este tipo de red neuronal convolucional conlleva una ventaja sustancial en comparación con redes neuronales pre entrenadas como YOLO, Inception, EfficientNet o ResNet. Una de estas ventajas es la personalización completa de la arquitectura según las necesidades como el tamaño de las imágenes o el tipo de características que se desee capturar. En este contexto, las redes neuronales pre entrenadas suelen estar optimizada para conjuntos de datos específicos. Adicional a esto las redes neuronales pre entrenadas son generalmente grandes, lo cual afecta directamente al número de parámetros y a un mayor consumo de memoria. Es por esto, que se optó por el desarrollo de una CNN en lugar de utilizar una red neuronal pre entrenada como las antes mencionadas.

La CNN utilizada en este trabajo para la detección profunda del melanoma maligno en la piel tiene por entrada un conjunto de imágenes de las cuales la red neuronal es capaz de extraer de manera automática una serie de características. Como bien se explica, la CNN tiene por entrada imágenes de tamaño $227 \times 227 \times 3$ donde estos valores son correspondientes a la longitud, anchura y tamaño del canal. Dado que el conjunto de imágenes de entrada a la red neuronal consta de imágenes a color se establece el tamaño de canal con un valor de 3. Una vez explicada la entrada de datos correspondiente a la CNN exhibe de manera detallada la implementación de cada una de las capas desarrolladas para esta red neuronal.

La red neuronal implementa capas convolucionales de 8, 16 y 32 filtros respectivamente. Estos filtros son fundamentales para la extracción de aspectos en las imágenes, se podría decir que es la base principal de toda la arquitectura. Se utiliza una normalización por lotes la cual es repartida por toda la red, esta se encarga de normalizar y estabilizar la activación de la capa anterior, ayudando a la velocidad de entrenamiento y a su estabilización.

Adicional a esto, se utiliza la función de activación ReLU (Rectified Linear Unit) esta función es usada para introducir no linealidad al modelo de red neuronal, al permitir que el modelo aprenda en función a complejas representaciones de los datos (Banerjee et al., 2019).

Para reducir la dimensión espacial de la salida de cada capa convolucional es necesario un proceso de agrupamiento máximo denominado Max Pooling Layers ya

que según el sitio web (DeepAi, s.f.) Esta es una técnica de muestreo descendente utilizada para reducir las dimensiones espaciales de un volumen de entrada. Sirve para crear representaciones más pequeñas y manejables reduciendo el tamaño de los parámetros y cálculos de la red. En este caso, se utiliza el Max Pooling Layers con un tamaño de 2x2 seguido por unos strides 2.

Una de las capas tiene todas las neuronas conectadas entre sí, esta ayuda a la función ReLU con sus procesos de activación en las capas anteriores. Esta capa comprende de 100 neuronas en una capa oculta y dado que se trata de una clasificación binaria, la red neuronal, en su capa de salida comprende de 2 neuronas. El propósito de esta capa es combinar todos los aspectos aprendidos en cada capa a través de los datos ingresados, de esta manera es posible identificar grandes patrones sobre los datos.

En la capa de salida, además de implementar 2 neuronas conectadas, también se maneja la función de activación Softmax, esta es la que participa de calcular la distribución de probabilidad sobre las clases, permitiendo y favoreciendo la clasificación binaria.

Una vez construida e implementada la capa de entrada, las capas ocultas y la capa salida de la red neuronal se hace uso del optimizador SGD para obtener el mínimo error posible.

3.4. ENTRENAMIENTO DEL MODELO

Para el entrenamiento del modelo se utilizó 2016 imágenes (1008 melanoma benigno y 1008 melanoma maligno) divididas de manera uniforme asegurando un balance para un óptimo entrenamiento. Todas las imágenes digitales están en formato JPG.

En el entrenamiento también se utilizaron dos tipos de callbacks tales como EarlyStopping y ReduceLROnPlateau. Estos callbacks tienen como finalidad mejorar significativamente el rendimiento y la eficiencia del modelo de red neuronal.

EarlyStopping: Según la documentación del sitio web (Keras, s.f.) Este callback ayuda a prevenir el sobreajuste y ahorra tiempo y recursos al detener el entrenamiento cuando el rendimiento en el conjunto de validación deja de mejorar. Es decir, interrumpe el entrenamiento cuando una métrica supervisada deja de

mejorar. En la tabla #2 se pueden observar los valores de los argumentos usados en el EarlyStopping, asimismo su función que desempeñan cada argumento dentro del modelo.

Tabla 2. Argumentos de EarlyStopping

Argumento	Valor	Función
Monitor	val_loss	Métrica para monitorear
Patience	10	Cantidad de épocas consecutivas sin progreso tras las cuales se finaliza la sesión de entrenamiento
Restore_best_weights	True	Repone los pesos del modelo con el valor más alto de la métrica monitoreada

Nota. Fuente: Elaboración propia

ReduceLROnPlateau: Según la documentación de Keras (Keras, s.f.) ReduceLROnPlateau ajusta dinámicamente la tasa de aprendizaje para permitir una mejor convergencia del modelo cuando el progreso se estanca. En la tabla #3, igual que con EarlyStopping, se explican los argumentos usados en el callback.

Tabla 3. Argumentos de ReduceLROnPlateau

Argumento	Valor	Función
Monitor	val_loss	Métrica para monitorear
Factor	0.2	Factor por el cual se reducirá la tasa de aprendizaje ($nueva_lr = lr * factor$)
Patience	5	La cifra de épocas sin progreso luego de las cuales se reducirá la tasa de aprendizaje
Min_lr	0.001	Tasa de aprendizaje mínima

Nota. Fuente: Elaboración propia

En el proceso de entrenamiento de la red neuronal convolucional (CNN), se configuraron 40 épocas, lo que implica que el modelo pasaría por el dataset de entrenamiento 40 veces para ajustar sus parámetros y minimizar la función de pérdida. Sin embargo, gracias a la implementación del callback conocido como EarlyStopping, el entrenamiento no necesariamente se extiende a la totalidad de estas épocas.

Asimismo, la tasa de aprendizaje (learning rate) es un hiperparámetro crucial que controla la magnitud de las actualizaciones de los pesos del modelo en cada paso del descenso de gradiente. En este contexto, se utilizó una tasa de aprendizaje con la que empieza a trabajar el algoritmo es de 0.01, un valor comúnmente elegido por su balance entre la velocidad de convergencia y la estabilidad del entrenamiento. Sumado a esto para equilibrar la necesidad de una rápida convergencia inicial con la estabilidad y precisión en etapas posteriores del entrenamiento, se implementó el callback ReduceLRonPlateau. Debido a que se mencionó anteriormente este callback ajusta dinámicamente la tasa de aprendizaje en función del rendimiento del modelo en el conjunto de validación.

Tabla 4. Parámetros de entrenamiento

Parámetros	Valores
Número de muestras	2016 (1008 malignas y 1008 benignas)
Número de épocas	40
Número de épocas recorridas	21
Tasa de aprendizaje	0.01
Callbacks	EarlyStopping, ReduceLRonPlateau
Tamaño de lote	16

Nota. Fuente: Elaboración propia

En el contexto del entrenamiento de redes neuronales con grandes conjuntos de datos, es común utilizar generadores de datos (data generators) que permiten alimentar al modelo con lotes (batches) de datos de manera secuencial. Esto es particularmente útil cuando los datos no caben completamente en la memoria. Dos argumentos importantes en este proceso son “pasos por épocas” y “pasos por validación”. Para ambos argumentos el valor fue calculado como la división entera del conjunto de datos entre el tamaño del lote.

$$\text{Pasos por épocas} = \frac{\text{conjunto de datos de entrenamiento}}{\text{tamaño del lote}}$$

$$\text{Pasos por validación} = \frac{\text{conjunto de datos de validación}}{\text{tamaño del lote}}$$

Para este entrenamiento se utilizó la plataforma Google Colab Pro, aprovechando las capacidades avanzadas que ofrece en términos de recursos computacionales. Google Colab Pro proporciona acceso a aceleradores de hardware, como las Tensor Processing Units (TPUs), que son diseñadas específicamente para

optimizar y acelerar las tareas de entrenamiento de modelos de aprendizaje profundo. Como lenguaje de programación fue usado Python aprovechando su extensa biblioteca de herramientas y recursos para el desarrollo de proyectos de Deep learning. Python es ampliamente reconocido por su simplicidad y eficacia en la implementación de algoritmos de machine learning. En este proyecto, se utilizaron bibliotecas de Python como TensorFlow y Keras para construir, entrenar y evaluar el modelo.

4. RESULTADOS Y DISCUSIÓN

En este capítulo, se presenta una evaluación exhaustiva de los resultados obtenidos mediante la implementación y entrenamiento de la CNN diseñada para la clasificación de imágenes de melanoma y no melanoma. El propósito primordial de esta sección es analizar el desempeño del modelo propuesto a través de diversas métricas de evaluación, así como visualizar y discutir los resultados más relevantes logrados en base al proceso de validación y prueba.


Se detalla la exactitud del modelo, la pérdida de datos, y otras métricas clave como la matriz de confusión, el área bajo la curva (AUC) ROC, y las puntuaciones de F1, precisión y recall. Además, se presentarán gráficos que ilustran la pérdida y precisión durante el entrenamiento, lo que permitirá observar el comportamiento del modelo a lo largo de las épocas.

4.1. EVALUACIÓN DEL MODELO DE RED NEURONAL

La evaluación de una red neuronal es un paso crucial en el desarrollo de modelos de aprendizaje profundo. Una vez que la red ha sido entrenada, es fundamental medir su rendimiento para asegurarse de que el modelo generaliza bien a datos no vistos y cumple con los objetivos esperados. Este proceso de evaluación proporciona una comprensión clara de la efectividad del modelo y ayuda a identificar áreas donde puede haber mejoras.

Para evaluar la convergencia del algoritmo durante el proceso de entrenamiento, se graficaron las curvas de pérdida (loss) tanto para el conjunto de entrenamiento como para el conjunto de validación en función de las épocas recorridas. En particular, se utilizó la entropía cruzada binaria (binary cross-entropy) como función de pérdida para este problema de clasificación.

Ilustración 17. Gráfica de la pérdida de la validación y entrenamiento




Nota. Fuente: Elaboración propia

En la ilustración #16 se observa el gráfico de la pérdida del algoritmo en función de las épocas. Esta medida nos permite ver qué tan bien el modelo se ajusta a los datos de entrenamiento. Por ello, al analizar el gráfico es visible que la pérdida tanto en los datos de validación como de entrenamiento llega a valores cercanos a 0, entendiéndose entonces que el sistema adquiere un ajuste correcto a los datos de entrenamiento.

La exactitud (accuracy) es otra métrica clave que se utilizó para evaluar el rendimiento del modelo. Se calcularon y graficaron las precisiones del entrenamiento y validación a lo largo de las épocas. Las curvas de precisión proporcionan información sobre la tasa de predicciones correctas que realiza el modelo.

Ilustración 18. Exactitud del entrenamiento y validación



Nota. Fuente: Elaboración propia

Al igual que el gráfico anterior, en la ilustración #17 se visualiza la exactitud en función de las épocas transcurridas. Puesto que con el pasar de las épocas, la precisión va en aumento, dando un significado que el modelo se está ajustando correctamente al entrenamiento.

Estos gráficos presentados anteriormente muestran el estado de eficiencia del modelo. Es por ello por lo que el modelo fue evaluado tanto en datos de testeo como en datos de validación. En la tabla # se muestra la evaluación con los valores correspondientes.

Tabla 5. Valores de pérdida y exactitud


	Datos de validación	Datos de prueba
Pérdida	0.06	0.06
Exactitud	98.36%	97.77%

Nota. Fuente: Elaboración propia

Sumada al conjunto de herramientas para evaluar el rendimiento del modelo de red neuronal, se tiene la curva ROC y su valor AUC-ROC. Un AUC-ROC de 0.99 obtenido una predicción de la arquitectura la colección de datos de testeo indica que el modelo tiene un rendimiento excelente en la tarea de clasificación binaria. Este valor cercano a 1 sugiere que el modelo es capaz de distinguir muy bien entre las clases positivas y negativas, con una alta sensibilidad y una baja tasa de falsos positivos. En términos prácticos, un AUC-ROC de 0.99 significa que el modelo tiene

una probabilidad del 99% de clasificar correctamente un ejemplo positivo frente a un ejemplo negativo al azar. Siendo así, el área bajo la curva ROC muestra de manera gráfica el desempeño al momento de realizar una predicción.

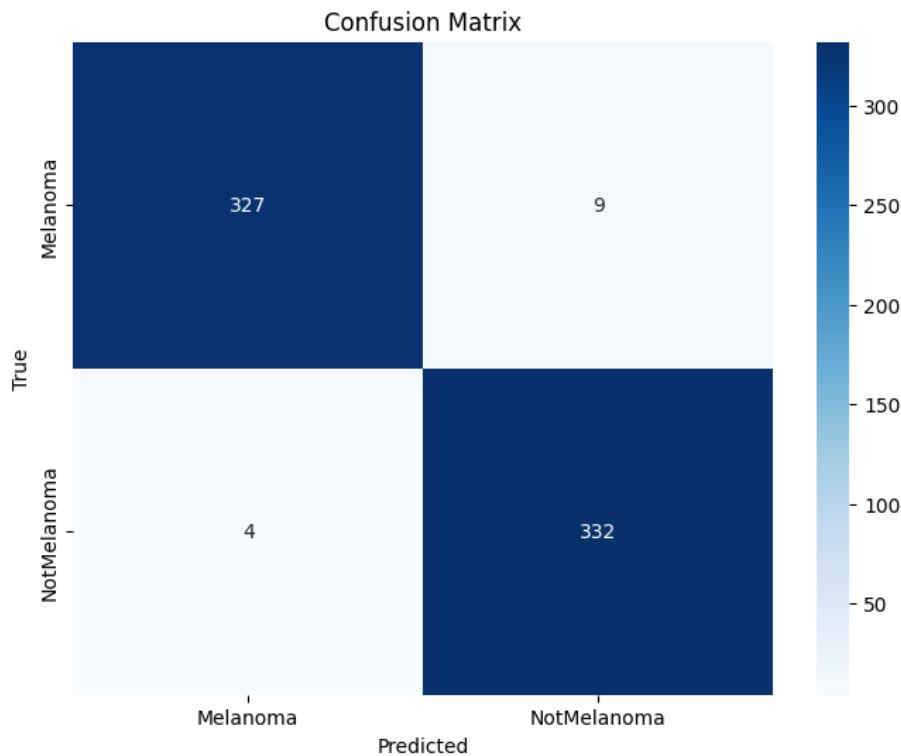
Ilustración 19. Gráfico de curva ROC



Nota. Fuente: Elaboración propia

Por último, como medida final de evaluación se obtuvo la matriz de confusión, donde mostrará el valor tanto de verdaderos positivos como el de verdaderos negativos. Los cuales son de nuestro interés. Para un problema de clasificación binaria, la matriz de confusión se presenta como una tabla de 2x2.

Ilustración 20. Matriz de confusión



Nota. Fuente: Elaboración propia

En el cuadrante superior izquierdo de la matriz de confusión nos muestra el número de verdaderos positivos, es decir, 327 muestras fueron clasificadas correctamente como melanoma. De igual forma, en el cuadrante inferior derecho muestra el número de verdaderos negativos, para este caso se puede interpretar que 332 casos fueron clasificados correctamente como benigno. Esta interpretación muestra como la diagonal principal de la matriz de confusión tiene los valores más altos, lo que indica que gran parte de los casos fueron clasificados correctamente ya sea para melanoma maligno o benigno.

Como errores de tipo I se toman los falsos positivos en la matriz de confusión en estas, 4 muestras según el algoritmo fueron predichas como melanoma cuando en realidad el paciente no presenta la patología. Del mismo modo, en los errores de tipo II correspondiente a los falsos negativos de las cuales 9 muestras donde el algoritmo no predice correctamente que el paciente padece de melanoma, cuando en realidad el paciente si padece la enfermedad.

En base a estas predicciones y a los valores resultantes de la matriz de confusión se pueden obtener métricas que evalúan en sí, el rendimiento del modelo.

A continuación, en la tabla 6 se exponen los valores que se obtuvieron al realizar las predicciones en función del registro de datos de testeo.

Tabla 6. Métricas de evaluación

Métrica	Valor
Exactitud	97.77%
Precisión	97.79%
Recall	97.77%
F1 Score	97.77%
AUC	99.81%

Nota. Fuente: Elaboración propia

En conjunto, estas métricas indican que el modelo tiene un rendimiento excelente. La alta exactitud, precisión, recall y F1 score, junto con un AUC muy cercano a 1, sugieren que el modelo no solo es eficaz en la clasificación general, sino que también es robusto en la identificación de ejemplos positivos y en la minimización de errores. Este nivel de rendimiento es indicativo de un modelo bien ajustado y eficaz para la tarea específica de clasificación en la que se ha entrenado.

Pese a que se obtuvieron excelentes resultados, existe un margen de mejora tanto en las métricas de predicción como en la evaluación del modelo. Para ello, como parte de las limitaciones de este trabajo, se sugiere aplicar nuevas técnicas para futuras mejoras tales como: ajustar los umbrales de decisión ayudando a encontrar un mejor equilibrio entre las métricas, aplicar métodos de aumento de datos para perfeccionar la variabilidad de los datos de entrenamiento, entre otras técnicas que podrían ayudar a superar este margen, dando como resultado un algoritmo con una clasificación superior.

5. CONCLUSIONES Y RECOMENDACIONES

5.1. CONCLUSIONES

- La revisión literaria confirmó que existe una basta integración de las arquitecturas de redes neuronales para la identificación de enfermedades dermatológicas, no sólo enfocadas en el melanoma, sino que abarca más campos dermatológicos, siendo así un área de investigación prometedora y en constante evolución.
- La recopilación de datos de fuentes libres como Kaggle ha demostrado ser un recurso importante para todo el proceso de implementación de sistemas de aprendizaje profundo en el ámbito del descubrimiento de melanoma. El uso de algoritmos y técnicas como RullRazor y Unsharp Masking para eliminar vellos y aplicar capas a las imágenes fueron un factor clave para realizar una mejora a la calidad de las imágenes facilitando así el entrenamiento del modelo. Estos métodos permitieron obtener un conjunto de datos limpios y con una mejora de calidad significativa.
- Se diseñó de manera meticulosa la arquitectura de la CNN para obtener éxito en la clasificación de imágenes. Una correcta combinación de capas y técnicas de optimización mejora la capacidad de aprender y generalizar de manera eficiente los respectivos datos.
- En términos de implementación y entrenamiento de la CNN para la clasificación de imágenes se puede expresar como un proceso integral que involucró el diseño del modelo y la optimización de los hiperparámetros para el entrenamiento. El éxito reflejado en los resultados obtenidos es producto de un diseño cuidadoso y una implementación rigurosa, demostrando así que es posible desarrollar modelos de aprendizaje profundo con soluciones precisas en el ámbito de la salud.
- El modelo propuesto mostró un excelente funcionamiento en la clasificación de imágenes, alcanzando una exactitud del 97.77% y una

pérdida del 0.06 en datos de prueba. No obstante, las métricas de predicción obtenidas sobre el modelo indican que este aún tiene un margen para mejorar en términos de generalización y robustez. Los gráficos presentaron de manera visual los resultados obtenidos mediante la evaluación de dicho modelo.

- Los resultados obtenidos permitieron identificar áreas de mejora que, si se abordan de manera correcta, se puede llegar a un modelo de mayor fiabilidad. Las estrategias propuestas como el aumento de datos y el ajuste de los umbrales se presentan como una alternativa para la optimización del modelo. Por ende, estos hallazgos contribuyen al avance del campo de la identificación automatizada del melanoma.

5.2. RECOMENDACIONES

En base a los descubrimientos y conclusiones de este trabajo, se ofrecen las siguientes pautas para futuras investigaciones y mejoras en la clasificación de imágenes de melanoma:

- Tomar en consideración aumentar más datos de entrenamiento, en especial las imágenes de melanoma, abordando así el desequilibrio de clases y mejorando la generalización del modelo.
- Explorar técnicas de procesamientos distintas a las usadas en este trabajo, con el objetivo de destacar de mejor manera las características relevantes en las imágenes.
- Realizar la evaluación del sistema en una colección de datos independiente para monitorear su desempeño y adaptabilidad a nuevas imágenes. Esto puede involucrar el desarrollo e implementación de un sistema de monitoreo con imágenes en tiempo real que detecte y ajuste el modelo según convenga.
- Proponer la viabilidad de integración en un ambiente real, como entornos clínicos, en colaboración de dermatólogos para validar la efectividad del modelo en escenarios reales. Esta integración también podría ser beneficiosa para la recopilación de nueva información mejorando de manera progresiva y continua el modelo.

BIBLIOGRAFÍA

- Acosta, Á. E., Fierro, E., Velásquez, V. E., y Rueda, X. (2009). Melanoma: patogénesis, clínica e histopatología. *Revista de la Asociación Colombiana de Dermatología y Cirugía Dermatológica*, 7(2), 87-108.
- Anwar, S. M., Majid, M., Qayyum, A., Awais, M., Alnowami, M., y Khan, M. K. (2018). Medical Image Analysis using Convolutional Neural Networks: A Review. *J Med Syst*, 42(226), 1-13. <https://doi.org/10.1007/s10916-018-1088-1>
- Ávila-Tomás, J. F., Mayer-Pujadas, M. A., y Quesada-Varela, V. J. (2021). La inteligencia artificial y sus aplicaciones en medicina II: importancia actual y aplicaciones prácticas. *Aten Primaria*, 53(1), 81-88. <https://doi.org/10.1016/j.aprim.2020.04.014>
- Banerjee, C., Mukherjee, T., y Pasilio, E. L. (2019). An Empirical Study on Generalizations of the ReLU Activation Function. *Proceedings of the 2019 ACM Southeast Conference*, 164-167. <https://doi.org/10.1145/3299815.3314450>
- Banerjee, Singh, S. a., Chakraborty, S. K., Das, A. a., Bag, A. a., y Rajib. (2020). Melanoma diagnosis using deep learning and fuzzy logic. *Diagnostics*, 10(8), 577. <https://doi.org/10.3390/diagnostics10080577>
- Baxt, W. G. (1995). Application of artificial neural networks to clinical medicine. *The Lancet*, 346(8983), 1135-1138. [https://doi.org/10.1016/S0140-6736\(95\)91804-3](https://doi.org/10.1016/S0140-6736(95)91804-3)
- Beunza Nuin, J. J., Puertas Sanz, E., y Condés Moreno, E. (2020). *Manual práctico de inteligencia artificial en entornos sanitarios*. Elsevier Health Sciences.
- Cortés Osorio, J. A., Muriel, A., y Mendoza Vargas, J. A. (2011). Comparación cualitativa y cuantitativa de las técnicas básicas de umbralización global basadas en histogramas para el procesamiento digital de imágenes. *Scientia et Technica*, 3(49), 266-272. <https://doi.org/10.22517/23447214.1539>
- DeepAi. (s.f.). DeepAi: <https://deepai.org/machine-learning-glossary-and-terms/max->

- Keras. (s.f.). *Keras EarlyStopping*. Keras EarlyStopping: https://keras.io/api/callbacks/early_stopping/
- Keras. (s.f.). *Keras, ReduceLROnPlateau*. Keras, ReduceLROnPlateau: https://keras.io/api/callbacks/reduce_lr_on_plateau/
- Kim, J.-H., Seo, S.-Y., Song, C.-G., y Kim, K.-S. (2019). Assessment of Electrocardiogram Rhythms by GoogLeNet Deep Neural Network Architecture. *Journal of healthcare engineering*, 2019. <https://doi.org/10.1155/2019/2826901>
- Laine, A., y Huda, W. (2000). Enhancement by Multiscale Nonlinear Operators. En A. Laine, y W. Huda, *Handbook of Medical Imaging Processing and Analysis* (pp. 33-55).
- LeCun, Y., Bingio, Y., y Hinton, G. (2015). Deep learning. *Nature*, 521, 436-444. <https://doi.org/10.1038/nature14539>
- Lee, T., Ng, V., Gallagher, R., Coldman, A., y McLean, D. (1997). Dullrazor®: A software approach to hair removal from images. *Computers in Biology and Medicine*, 27(6), 533-543. [https://doi.org/10.1016/S0010-4825\(97\)00020-6](https://doi.org/10.1016/S0010-4825(97)00020-6)
- Marques, G., Agarwal, D., y De la Torre Díez, I. (2020). Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network,. *Applied Soft Computing*, 96(106691). <https://doi.org/10.1016/j.asoc.2020.106691>
- Moreno, A., Armengol, E., Béjar Alonso, J., Belanche Muñoz, L. A., Cortés García, C. U., Gavaldá Mestre, R., . . . Sánchez-Marré, M. (1994). Aprendizaje automático. En A. Moreno, E. Armengol, J. Béjar Alonso, L. A. Belanche Muñoz, C. U. Cortés García, R. Gavaldá Mestre, . . . M. Sánchez-Marré, *Aprendizaje automático* (p. 6). Edicions UPC.
- Pibernat, M. R. (1996). Bases del diagnóstico dermatológico. *Dermatología clínica*. Madrid: Mosby/Doyma Libros, SA, 9-17.
- Rouhiainen, L. (2018). ¿Qué es exactamente la inteligencia artificial? En L. Rouhiainen, *Inteligencia artificial* (pp. 16-17). Madrid: Alienta Editorial.

- Rouhiainen, L. (2018). Aprendizaje automático. En L. Rouhiainen, *Inteligencia Artificial: 101 cosas que debes saber hoy sobre nuestro futuro* (p. 21). Madrid: Alienta Editorial.
- Rouhiainen, L. (2018). Aprendizaje profundo. En L. Rouhiainen, *Inteligencia artificial 101 cosas que debes saber hoy sobre nuestro futuro* (pp. 21-22). Madrid: Alienta Editorial.
- Samis Anwar, R. S. (2023). EfficientNet Algorithm for Classification of Different Types of Cancer. *Artificial Intelligence and Applications*. <https://doi.org/10.47852/bonviewAIA32021004>
- Sandoval Serrano, L. J. (2018). Algoritmos de aprendizaje automático para análisis y predicción de datos. *Revista Tecnológica; no. 11*.
- Saul, A. (2015). Estudio de un enfermo de la piel. En A. Saul, *Saúl. Lecciones de dermatología 16e* (p. 19). McGraw-Hill Education.
- Schmidt, R. M. (2019). Recurrent Neural Networks (RNNs): A gentle Introduction and Overview. *arXiv preprint arXiv:1912.05911*. <https://doi.org/10.48550/arXiv.1912.05911>
- Shawon, Abedin, M. a., Majumder, K. F., Mahmud, A. a., Mishu, A. a., y Chowdhury, M. M. (2021). Identification of Risk of Occurring Skin Cancer (Melanoma) Using Convolutional Neural Network (CNN). *AIUB Journal of Science and Engineering (AJSE)*, 20(2), 47-51. <https://doi.org/10.53799/AJSE.V20I2.140>
- Sherif, F. a. (2019). Skin lesion analysis toward melanoma detection using deep learning techniques. *International Journal of Electronics and Telecommunications*, 65(4), 597-602. <https://doi.org/10.24425/ijet.2019.129818>
- Shrestha, A., y Mahmood, A. (2019). Review of Deep Learning Algorithms and Architectures. *IEEE Access*, 7, 53040-53065. <https://doi.org/10.1109/ACCESS.2019.2912200>
- Srivastava, G., Pradhan, N., y Saini, Y. (2022). Ensemble of Deep Neural Networks based on Condorcet's Jury Theorem for screening Covid-19 and Pneumonia

- from radiograph images. *Computers in Biology and Medicine*, 149, 105979.
<https://doi.org/10.1016/j.combiomed.2022.105979>
- Targ, S., Almeida, D., y Lyman, K. (2016). Resnet in resnet: Generalizing residual architectures. *arXiv preprint arXiv:1603.08029*.
<https://doi.org/10.48550/arXiv.1603.08029>
- Venkatesh, K. P., Raza, M. M., Nickel, G., Wang, S., y Kvedar, J. C. (Febrero de 2024). Deep learning models across the range of skin disease. *Digital Medicine*, 4(32).
- Yamashita, R., Nishio, M., Gian Do, R. K., y Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights Imaging*, 9, 611-629. <https://doi.org/10.1007/s13244-018-0639-9>
- Zewen, L., Fan, L., Wenjei, Y., Shouheng, P., y Jun, Z. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999-7019.
<https://doi.org/10.1109/TNNLS.2021.3084827>
- Zou, J., Han, Y., y Sung-Sau, S. (2008). Overview of Artificial Neural Networks. *Livingstone, D.J. (eds) Artificial Neural Networks. Methods in Molecular Biology™*, 458. https://doi.org/10.1007/978-1-60327-101-1_2