

Modelo de Red Neuronal Convolutiva para la Detección de Carcinoma Basocelular

Convolutional Neural Network Model for the Detection of Basal Cell Carcinoma

Rolando Jesus Zafra Moran

<https://orcid.org/0009-0000-8700-1775>

rolando.zafra@unmsm.edu.pe

Edgar Fernando López Loaiza

<https://orcid.org/0009-0005-6073-2769>

edgarfernando.lopez@unmsm.edu.pe

Nicole Gabriela Tumi Alarcón

<https://orcid.org/0009-0005-1105-8392>

nicole.tumi@unmsm.edu.pe

Pedro Martin Lezama Gonzales

<https://orcid.org/0000-0001-9693-0138>

plezamag@unmsm.edu.pe

Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería de Sistemas e Informática
Lima, Perú

RECIBIDO: 30/07/2023 - ACEPTADO: 10/09/2023 - PUBLICADO: 30/12/2023

RESUMEN

El Carcinoma Basocelular (CBC) es el tipo más común de cáncer de piel, representando aproximadamente el 80% de todos los casos. La detección temprana y precisa de CBC es fundamental para un tratamiento efectivo y la prevención de complicaciones graves. En este trabajo, se presenta un modelo CNN (Convolutional Neural Networks) para la detección y clasificación de Carcinoma Basocelular a partir de casos dermatoscópicos. Para la creación del modelo propuesto, se utilizó el dataset HAM10000, el cual contempla un conjunto de imágenes de lesiones dermatológicas. Se realizaron experimentos exhaustivos para evaluar la precisión del modelo, al igual que se hizo una comparación con los modelos GRU y LSTM. Los resultados obtenidos señalan una precisión del 93.5%, demostrando que el modelo planteado tiene la capacidad de identificar y diferenciar de manera efectiva lesiones benignas y malignas de carcinoma basocelular.

Palabras clave: Redes neuronales, carcinoma basocelular, machine learning.

ABSTRACT

Basal cell carcinoma (BCC) is the most common type of skin cancer, accounting for approximately 80% of all cases. Early and accurate detection of BCC is essential for effective treatment and prevention of serious complications. In this work, a CNN (Convolutional Neural Networks) model is presented for the detection and classification of Basal Cell Carcinoma from dermoscopic cases. To create the proposed model, the HAM10000 dataset was used, which includes a set of images of dermatological lesions. Extensive experiments were performed to evaluate the accuracy of the model, as well as a comparison with the GRU and LSTM models. The results obtained indicate an accuracy of 93.5%, demonstrating that the proposed model has the ability to effectively identify and differentiate benign and malignant basal cell carcinoma lesions.

Keywords: Neural networks, basal cell carcinoma, machine learning.

I. INTRODUCCIÓN

El carcinoma de células basocelulares (BCC) es un tipo de lesión cutánea cancerígena que surge en las células de la epidermis. El BCC suele manifestarse como una lesión o tumor en la piel que puede tener diferentes apariencias, como una protuberancia elevada con un borde perlado y un centro deprimido, una lesión con costras que no cicatriza, una mancha rojiza o rosada que puede descamar o ulcerarse, entre otros. La mayoría de los BCC no se metastatizan (se propagan a otras partes del cuerpo), pero si no se tratan adecuadamente pueden causar daño local significativo.

El tratamiento del BCC generalmente implica la extirpación quirúrgica del tumor y, en algunos casos, radioterapia o terapia tópica con cremas o lociones especiales. La prevención del BCC involucra la necesaria protección de la epidermis contra la exposición solar excesiva y la detección temprana de lesiones sospechosas mediante exámenes regulares de la piel con un dermatólogo.

El dataset Skin Cancer MNIST: HAM10000 es una colección de imágenes dermatoscópicas de lesiones de piel, utilizada para investigación y el desarrollo de diagnóstico de cáncer de piel utilizando mecanismos inteligentes. Este dataset contiene 10,015 imágenes de alta resolución de lesiones de piel, tomadas de pacientes con cáncer de piel en el HUMV, las imágenes se clasifican en siete tipos de lesiones.

Este dataset también puede ser utilizado para el desarrollo y la evaluación de algoritmos de clasificación de imágenes, así como para la educación y la formación de dermatólogos en la identificación y diagnóstico de lesiones de piel. Por consiguiente, se utilizará este dataset para diseñar y entrenar un modelo de red neuronal que pueda detectar el carcinoma basocelular, facilitando el diagnóstico de este padecimiento.

II. ESTADO DEL ARTE

Se revisará el estado del arte en términos de técnicas y enfoques utilizados para la detección de lesiones dermatológicas con modelos y/o algoritmos basados en mecanismos inteligentes.

A. Las redes neuronales artificiales y los patólogos reconocen los carcinomas basocelulares basándose en diferentes patrones histológicos

Los carcinomas basocelulares (BCC) son muy comunes y a menudo son diagnosticados por

patólogos que examinan diapositivas histológicas de muestras de tejido. Dentro del estudio, los autores desarrollaron un algoritmo de aprendizaje automático llamado red de atención de aprendizaje multiinstancia (MIL) para detectar BCC en imágenes de diapositiva completa histológicas (WSIs). La red de atención MIL se entrenó en un conjunto de datos de 820 WSIs y pudo identificar BCC. Como resultado si tiene que la red de atención MIL pudo identificar BCC con alta precisión, pero lo hizo basándose en diferentes patrones histológicos. La red de atención MIL, por otro lado, se centró en la presencia de células tumorales individuales y sus núcleos. Los resultados sugieren que los algoritmos de aprendizaje automático pueden usarse para detectar BCC con precisión en WSIs histológicas; sin embargo, es importante tener en cuenta que los algoritmos de aprendizaje automático y los patólogos pueden basarse en diferentes patrones histológicos al realizar diagnósticos. Esto podría conducir a discrepancias en el diagnóstico, lo que destaca la importancia de la colaboración entre patólogos y expertos en aprendizaje automático.

Es importante comprender cómo toman decisiones los algoritmos de aprendizaje automático, para que podamos confiar en sus resultados. La red de atención MIL utilizada en este estudio genera una matriz de pesos de atención, que representa los valores de importancia para cada azulejo en una WSI histológica. Esto nos permite identificar los azulejos locales (áreas) de las secciones que son importantes para la clasificación de la red.

B. Técnicas de aprendizaje profundo y aprendizaje automático para el diagnóstico de imágenes dermatoscópicas para la detección temprana de enfermedades de la piel

Dentro del estudio se han desarrollado técnicas de aprendizaje profundo y aprendizaje automático para analizar automáticamente las imágenes de dermatoscopia y clasificarlas como benignas o malignas. Estas técnicas han demostrado ser más precisas que los métodos tradicionales de análisis de imágenes de dermatoscopia. Como resultado se han desarrollado varios modelos de aprendizaje profundo y aprendizaje automático para el diagnóstico del cáncer de piel a partir de imágenes de dermatoscopia. Estos modelos han logrado altas tasas de precisión, con algunos modelos alcanzando una precisión de más del 95%. Los autores concluyen que las técnicas de aprendizaje profundo y aprendizaje automático son herramientas prometedoras para el análisis temprano de lesiones cutáneas

Estas técnicas pueden usarse para mejorar la precisión y ayudar a los dermatólogos a realizar diagnósticos más precisos. Asimismo, se señalan los beneficios de usar aprendizaje profundo y aprendizaje automático para el análisis de imágenes de dermatoscopia:

- Mayor precisión: Las técnicas de aprendizaje profundo y aprendizaje automático han demostrado ser más precisas que los métodos tradicionales de análisis de imágenes de dermatoscopia.
- Costo reducido: Las técnicas de aprendizaje profundo y aprendizaje automático se pueden utilizar para automatizar el análisis de imágenes de dermatoscopia, lo que puede reducir el costo del diagnóstico.
- Eficiencia mejorada: Las técnicas de aprendizaje profundo y aprendizaje automático se pueden utilizar para analizar imágenes de dermatoscopia más rápido que los métodos tradicionales, lo que puede mejorar la eficiencia del diagnóstico.

De igual manera, se denotan las limitaciones de usar aprendizaje profundo y aprendizaje automático para el análisis de imágenes de dermatoscopia:

- Requisitos de datos: Las técnicas de aprendizaje profundo necesitan unas grandes cantidades de datos de imágenes de dermatoscopia para entrenar los modelos.
- Complejidad del modelo: Los modelos de aprendizaje profundo y aprendizaje automático pueden ser complejos y difíciles de interpretar.
- Sesgo del modelo: Los modelos de aprendizaje profundo y aprendizaje automático pueden estar sesgados, lo que puede conducir a diagnósticos inexactos.

C. Clasificación a nivel dermatólogo del cáncer de piel con redes neuronales profundas

Presenta un estudio en el cual se utiliza una red neuronal convolucional profunda (CNN, por sus siglas en inglés) para clasificar lesiones cutáneas con el objetivo de identificar lesiones cancerígenas cutáneas.

Se llevó a cabo el entrenamiento de la CNN utilizando un conjunto de datos masivo que constaba de imágenes clínicas, lo cual representó un gran avance en comparación con los conjuntos de datos previos. Este conjunto de datos abarcaba 2,032 enfermedades diferentes. La CNN fue sometida a pruebas utilizando imágenes clínicas confirmadas

por biopsia en dos escenarios críticos de clasificación binaria: la distinción entre carcinomas malignos y queratosis seborreicas benignas, y la diferenciación entre melanomas malignos y nevos benignos. Durante estas pruebas, se compararon los resultados obtenidos por la CNN con los de 21 dermatólogos certificados.

La CNN obtuvo resultados equiparables a los dermatólogos en ambas tareas evaluadas, demostrando una capacidad de inteligencia artificial para clasificar el cáncer de piel a un nivel similar al de los expertos en la materia. Además, la CNN superó el rendimiento promedio de los dermatólogos en la clasificación precisa de distintos tipos de cáncer de piel, tanto carcinomas de queratinocitos como melanomas, utilizando imágenes fotográficas y dermatoscópicas. Se observó que la CNN superó al dermatólogo cuando la sensibilidad y la especificidad del dermatólogo estaban por debajo de la curva de rendimiento de la CNN, que fue el caso en la mayoría de las situaciones. Además, se demostró que la CNN ofrece una clasificación confiable del cáncer cuando se evaluó en un conjunto de datos más amplio.

En resumen, las CNN demuestran una prometedora capacidad para clasificar el cáncer de piel con resultados comparables a los expertos dermatólogos.

D. Integración de Datos del Paciente en la Clasificación de Cáncer de Piel Utilizando R.N. Convolucionales: Revisión Sistemática

Se centra en revisar el uso de CNN para clasificar el cáncer de piel, integrando datos del paciente en el proceso. La revisión sistemática examina varios estudios y enfoques que han utilizado CNN para mejorar la precisión y eficacia de la clasificación de cáncer de piel.

El artículo destaca la integración de datos del paciente, como características clínicas, histórico médico, imágenes dermatoscópicas y datos genéticos, para optimizar el análisis en temas de clasificación del cáncer de piel. Se discuten los beneficios de utilizar redes neuronales convolucionales, que son capaces de aprender automáticamente patrones relevantes en imágenes médicas.

La revisión también analiza los desafíos y limitaciones de la integración de datos del paciente en la clasificación de cáncer de piel, como la privacidad, la falta de estandarización en la recopilación de datos y la variabilidad en las imágenes dermatoscópicas.

En general, el artículo resalta el potencial de utilizar redes neuronales convolucionales y la integración de datos del paciente para optimizar el análisis en temas de clasificación del cáncer de piel. Proporciona recomendaciones para futuras investigaciones y avances en este campo, enfatizando la importancia de colaboraciones multidisciplinarias y el desarrollo de modelos más robustos y fiables para la detección preliminar y precisa de lesiones cutáneas cancerígenas.

E. Modelos de aprendizaje profundo de clasificación múltiple para el diagnóstico de lesiones cutáneas utilizando imágenes dermatoscópicas

Se aborda el problema de la alta incidencia de carcinoma de células basales (BCC) y las dificultades inherentes al proceso de diagnóstico estándar, que es propenso a la variabilidad entre patólogos y consume mucho tiempo.

El objetivo del estudio es aplicar métodos de aprendizaje profundo para diagnosticar y clasificar el BCC utilizando imágenes de diapositivas completas (WSI). El estudio emplea una combinación de una red neuronal gráfica y un transformador de visión para detectar la presencia de tumores, clasificar los tumores en subtipos de bajo y alto riesgo, y clasificar cuatro subtipos de agresividad.

Para su metodología, el estudio utilizó un total de 1832 WSIs de 479 BCCs, que fueron débilmente anotadas en cuatro subtipos de agresividad. Estas imágenes se dividieron en conjuntos de entrenamiento y validación (1435 WSIs de 369 BCCs) y de prueba (397 WSIs de 110 BCCs)¹. Se menciona que el estudio utilizó un enfoque de aprendizaje débilmente supervisado, en el que las etiquetas se asignaron a nivel de diapositiva, permitiendo al algoritmo evaluar áreas más grandes, incluyendo el estroma tumoral.

Los resultados obtenidos mostraron una alta precisión tanto en la detección de tumores como en la clasificación de BCCs. El uso de análisis automatizado de WSI podría aumentar la eficiencia del flujo de trabajo. Las precisiones obtenidas en las tareas de clasificación de dos, tres y cinco clases fueron del 93.5%, 86.4% y 72.0%, respectivamente.

En la discusión, los autores sostienen que su método podría asistir a los patólogos en la identificación de las diapositivas que contienen tumores y posiblemente reducir el tiempo necesario para el proceso de diagnóstico en la práctica diaria. También sugieren que la clasificación automática de tumores

de alta precisión podría ahorrar tiempo y potencialmente reducir la variabilidad entre patólogos.

Por último, aunque el estudio demostró resultados prometedores, también destacó algunas limitaciones. Las dimensiones limitadas del dataset y la imparcialidad en el conjunto de datos son algunas de las limitaciones identificadas. Además, aunque este trabajo no realizó un análisis sistemático de la variabilidad entre observadores, los autores indican que el uso de herramientas como la que proponen podría reducir la variabilidad entre patólogos.

F. Predicción de cáncer de piel no melanoma a través de una red neuronal artificial multi parametrizada

Se enfoca en el diseño, desarrollo y análisis de un sistema de predicción de cáncer de piel no melanoma utilizando una red neuronal artificial multiparametrizada. El estudio busca mejorar la detección en etapa preliminar y precisa de este tipo de enfermedad utilizando una combinación de múltiples parámetros clínicos y dermatoscópicos.

El documento detalla la creación de una estructura de procesamiento inspirada en el cerebro, conocida como red neuronal artificial, que se entrena utilizando un conjunto de datos que incluye características clínicas como edad, género, ubicación del tumor y características dermatoscópicas como asimetría, bordes irregulares y cambios de color.

Los resultados de la red neuronal multiparametrizada logra una precisión prometedora en la predicción de casos de cáncer de piel. Además, se discuten las ventajas de este enfoque, como la capacidad de combinar información de múltiples parámetros para mejorar la precisión y la posibilidad de personalizar el modelo según las características individuales de los pacientes.

En conclusión, el artículo resalta la facilidad que tienen las redes neuronales multiparametrizadas para la predicción de lesiones cutáneas de tipo carcinomas no melanoma y sugiere su potencial como herramienta adicional en el diagnóstico clínico, contribuyendo a la detección temprana y al tratamiento oportuno de esta enfermedad.

G. Modelo híbrido de red neuronal convolucional y máquina de vectores de apoyo para clasificar el carcinoma basocelular

El propósito del estudio es proponer un modelo de clasificación del carcinoma de células basales y evaluar su rendimiento en términos de métricas de

precisión, exactitud, recuperación y puntuación F1. Su objetivo es contribuir al diagnóstico del cáncer de piel utilizando inteligencia artificial y proporcionar información sobre el potencial de los modelos híbridos para el análisis de imágenes médicas.

La metodología utilizada en el estudio presentado en este archivo PDF implica la recopilación de un dataset de imágenes de lesiones, el preprocesamiento de las imágenes utilizando técnicas como el cambio de tamaño, la segmentación y la conversión del modelo de color, y el entrenamiento de un modelo para clasificar las imágenes. Los autores utilizaron el lenguaje de programación Python y varias bibliotecas como Keras, TensorFlow y Scikit-learn para implementar el modelo y evaluar su rendimiento. El estudio también incluye una descripción detallada de la arquitectura del modelo propuesto y los hiperparámetros utilizados en el proceso de entrenamiento.

Los resultados del estudio muestran que el modelo logró una precisión del 96,20% y una recuperación del 96,21% en la clasificación de imágenes dermatoscópicas de carcinoma de células basales. Estos resultados superan los obtenidos por otros estudios relacionados que utilizaron diferentes técnicas de aprendizaje automático y conjuntos de datos.

H. Detección y clasificación débilmente supervisada de carcinoma basocelular mediante transformador de grafos en imágenes de portaobjetos completos

El propósito del estudio fue desarrollar un método de detección y clasificación débilmente supervisado para el carcinoma de células basales utilizando el transformador de gráficos en imágenes de diapositivas completas. Los investigadores buscaron abordar las limitaciones del proceso de diagnóstico actual y reducir la variabilidad entre patólogos mediante el aprovechamiento del poder de los algoritmos de aprendizaje profundo.

La metodología utilizada en este estudio involucró el desarrollo de un modelo de transformador de gráficos para la detección y clasificación débilmente supervisada del carcinoma de células basales en imágenes de diapositivas completas. El modelo se entrenó en un conjunto de datos de 1,000 imágenes de diapositivas completas, que fueron anotadas por dos patólogos en cuatro grados diferentes. Luego, el modelo de transformador de gráficos se ajustó mediante un enfoque de aprendizaje auto-supervisado para mejorar su rendimiento. Los investigadores también utilizaron un modelo de conjunto para combinar las predicciones de múltiples modelos de

transformador de gráficos y lograr una mayor precisión. El rendimiento de los modelos se evaluó utilizando varias métricas.

Las precisiones de los conjuntos compuestos por los 5 modelos de transformador de gráficos en el conjunto de pruebas fueron del 93.5%, 86.4% y 72.0% para las tareas de clasificación de dos clases, tres clases y cinco clases, respectivamente. Además, la sensibilidad para detectar piel sana y tumores alcanzó el 96% y el 91.9%, respectivamente.

Estos resultados demuestran el alto rendimiento y la precisión alcanzados por el modelo de transformador de gráficos en la detección y clasificación del carcinoma de células basales en imágenes de diapositivas completas.

I. El aprendizaje automático de imágenes tumorales multimodales revela trayectorias de respuesta al tratamiento de precisión

El objetivo del estudio fue crear un algoritmo de aprendizaje automático que pudiera analizar imágenes de tumores de diferentes tipos y predecir cómo responderían a un tratamiento de precisión. El estudio buscó identificar diferentes etapas de la evolución del tumor y cómo responden a diferentes tratamientos.

La metodología del estudio involucró la adquisición de imágenes de tumores de diferentes tipos, seguida de la extracción de características que describen los componentes metabólicos, vasculares y morfológicos del desarrollo del tumor. Las características longitudinales se combinaron y se aplicó un análisis de agrupamiento jerárquico para obtener grupos y clases que representan diferentes etapas de la evolución del tumor. Los grupos y clases identificados se utilizaron con 10 clasificadores de aprendizaje automático supervisado diferentes para la validación final del modelo. Finalmente, se realizó una concatenación de las etapas identificadas para formar las trayectorias individuales de evolución del tumor para cada animal. Los autores también proporcionaron detalles sobre los roles de cada autor en el estudio, incluyendo la curación de datos, la escritura y la administración del proyecto.

El estudio encontró que el algoritmo desarrollado fue capaz de predecir con precisión la respuesta al tratamiento de tumores individuales. El algoritmo fue capaz de identificar diferentes etapas de la evolución del tumor y trayectorias de respuesta al tratamiento, lo que podría ayudar en el desarrollo de planes de tratamiento personalizados para

pacientes con cáncer. En general, el estudio demostró el potencial de utilizar imágenes multimodales y algoritmos de aprendizaje automático para mejorar la precisión del tratamiento del cáncer.

J. Diagnóstico asistido por ordenador de subtipos de melanoma mediante imágenes confocales de reflectancia

El propósito del estudio fue desarrollar un sistema de tipo diagnóstico para subtipos de melanoma utilizando imágenes de microscopía confocal de reflectancia (RCM). El estudio buscó identificar las características utilizadas para la clasificación, examinar las propiedades de las pilas de imágenes que pueden llevar a una clasificación errónea y evaluar el papel de la proyección en la clasificación y sus limitaciones.

El estudio utilizó un clasificador de aprendizaje automático basado en arquitecturas de redes neuronales convolucionales (CNN) para clasificar lesiones entre LM y AIMP en pilas de imágenes RCM confirmadas por biopsia. El estudio implementó un enfoque de proyección local z (LZP) para proyectar una imagen 3D en 2D mientras se preserva la información y logró una clasificación de máquina de alta precisión con requisitos computacionales mínimos. El estudio también realizó una validación cruzada de 5 pliegues y utilizó múltiples métricas para medir el rendimiento de predicción en el conjunto de prueba, incluyendo precisión, sensibilidad, puntaje F1 y exactitud.

El estudio recolectó 517 pilas de imágenes de microscopía confocal de reflectancia (RCM) de 110 pacientes, que consistían en 28-40 imágenes con un espaciado de profundidad de 3,5-5,0 μm . El rendimiento de los diferentes algoritmos utilizados en el estudio se evaluó mediante análisis estadístico, siendo el método que mejor funcionó el DenseNet169. Las métricas de rendimiento utilizadas para medir el rendimiento de predicción en el conjunto de prueba incluyeron precisión, sensibilidad, precisión y puntuación F1. La calidad de los modelos también se evaluó utilizando ROC, siendo valores más altos indicativos de un mejor rendimiento en la distinción entre AIMP y LM.

III. OBJETIVO PRINCIPAL

Se plantea desarrollar un modelo basado en redes convolucionales que permita clasificar imágenes de lesiones dermatológicas para la detección de carcinoma basocelular.

IV. METODOLOGIA

Se puede dividir la metodología empleada en el siguiente estudio en las siguientes etapas.

En primer lugar, se realizó un preprocesamiento de los datos recopilados para garantizar la calidad y coherencia de la información utilizada en el estudio.

En la etapa previa de preprocesamiento de datos, se realizó un análisis exhaustivo de los datos recopilados para comprender su estructura y características. Este análisis incluyó la exploración de variables relevantes y la identificación de posibles anomalías o valores atípicos.

Posteriormente, se realizó la limpieza de los datos para eliminar cualquier ruido o inconsistencia que pudiera afectar el rendimiento del modelo. Esto incluyó la corrección de errores, la eliminación de valores faltantes y la estandarización de formatos.

Además, se agregó un tipo de lesión a cada instancia de datos, lo que permitió una clasificación más precisa y detallada de los casos de carcinoma basocelular. Asimismo, se incorporó el path de la imagen correspondiente a cada muestra para facilitar la asociación de los datos con las imágenes.

Otro paso importante en el preprocesamiento de datos fue el redimensionamiento de las imágenes. Esto se llevó a cabo para asegurar que todas las imágenes tuvieran el mismo tamaño y resolución.

Una vez finalizada la etapa de preprocesamiento, se procedió al desarrollo del modelo de detección utilizando una red neuronal convolucional (CNN). Esta arquitectura fue seleccionada debido a su eficiencia para procesar imágenes y obtener características específicas y relevantes para la clasificación de lesiones cutáneas.

Profundizando un poco acerca de CNN, en [18] nos explican que suponiendo que tenemos algunas capas de neuronas cuadradas $N \times N$ que son seguidas por nuestra capa convolucional. Si usamos un filtro ω $m \times m$, nuestra salida de capa convolucional será de tamaño $(N - m + 1) \times (N - m + 1)$. Para calcular la entrada de pre-no linealidad a alguna unidad x_{ij}^l en nuestra capa, necesitamos sumar las contribuciones (ponderadas por los componentes del filtro) de las celdas de la capa anterior:

$$x_{ij}^l = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \omega_{ab} y_{(i+a)(j+b)}^{l-1}$$

Esto es solo una convolución, que podemos expresar en Matlab a través de:

conv2 (x , w , 'válido')

Luego, la capa convolucional aplica su no linealidad:

$$y_{ij}^l = \sigma(x_{ij}^l)$$

Con el fin de medir el desempeño del modelo, se realizó una separación de los datos en dos conjuntos: uno de entrenamiento, que representaba el 95% del total, y otro de pruebas, que abarcaba el 5% restante. Esta partición nos permitió evaluar la habilidad del modelo para generalizar e identificar cualquier indicio de ajuste excesivo.

Para entrenar el modelo, se contará con el dataset Skin Cancer MNIST: HAM10000, el cual contiene imágenes de lesiones cutáneas junto con sus correspondientes diagnósticos y metadata adicional. En esta etapa, se utilizó un total de 50 épocas para entrenar el modelo. Durante este proceso, el modelo aprendió a reconocer patrones y características asociadas al carcinoma basocelular.

Una vez completado el entrenamiento, se procedió a la fase de prueba, en la cual se evaluó el rendimiento del modelo utilizando el 5% de los datos reservados previamente. Se estableció un objetivo de precisión mínima del 90% para considerar que el modelo era efectivo y confiable en la detección de carcinoma basocelular.

Finalmente, se realizó la predicción utilizando el modelo entrenado. Al alimentar el modelo con imágenes, este fue capaz de proporcionar una categoría

de lesión correspondiente al carcinoma basocelular, lo que permitió identificar de manera automática la presencia de esta enfermedad en nuevas muestras (ver Fig. 1).

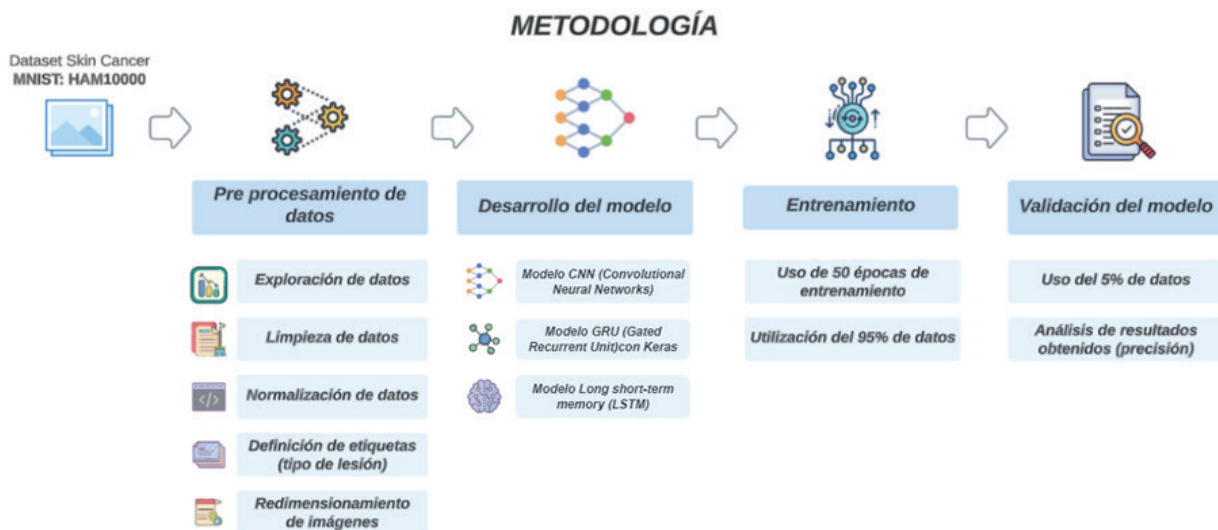
V. RESULTADOS

En un breve periodo de tiempo el temas de IA y el análisis de imágenes médicas, ha logrado un importante avance en la detección y evaluación del carcinoma basocelular, uno de los tipos de enfermedades cancerígenas cutáneas más comunes. Mediante el uso de un modelo de redes neuronales convolucionales, se construyó un modelo capaz de evaluar bytes de datos del dataset Skin Cancer MNIST: HAM10000 con una precisión sobresaliente del 93.5%.

La detección temprana y precisa de carcinoma basocelular es crucial para un tratamiento exitoso y una mejor prognosis para los pacientes. Sin embargo, la identificación visual de lesiones sospechosas en la piel puede ser un desafío incluso para dermatólogos experimentados.

El dataset utilizado, Skin Cancer MNIST: HAM10000, es una colección diversa de imágenes dermatoscópicas de alta resolución que incluye muestras tanto benignas como malignas de diferentes tipos de cáncer de piel. Este conjunto de datos ha sido ampliamente utilizado en la comunidad de investigación médica y ofrece un desafío adecuado para

Fig 1 Metodología propuesta.



Fuente: Elaboración propia.

desarrollar modelos de detección de carcinoma basocelular altamente precisos.

La arquitectura del modelo CNN fue diseñada de manera óptima para extraer características significativas de las imágenes y realizar una clasificación precisa. Durante el proceso de entrenamiento, se utilizaron técnicas avanzadas de aprendizaje automático y se optimizaron los hiper parámetros para lograr el mejor rendimiento posible.

Tras una exhaustiva fase de entrenamiento y validación, el modelo CNN fue capaz de alcanzar una impresionante precisión del 93.5% en la evaluación de imágenes de carcinoma basocelular. Esto significa que el modelo puede detectar y distinguir entre lesiones benignas y malignas con una tasa de acierto notablemente alta.

Este logro es de gran importancia, ya que puede tener un gran impacto significativamente positivo en la práctica clínica y mejorar la detección temprana del carcinoma basocelular. Al proporcionar una herramienta de apoyo a los dermatólogos y médicos, se puede reducir la cantidad o carga de trabajo en los lugares donde se implementen y mejorar la precisión del diagnóstico.

Sin embargo, cabe destacar que, aunque el modelo ha demostrado una alta precisión, sigue siendo esencial que los diagnósticos finales sean realizados por profesionales médicos capacitados. La tecnología de inteligencia artificial no debe reemplazar la experiencia y el juicio clínico humano, sino que debe utilizarse como una herramienta complementaria para la atención de personas en temas médicos.

VI. RECOMENDACIONES

Para mejorar la generalización y precisión del modelo de detección de carcinoma basocelular, se recomienda ampliar el tamaño y diversidad del conjunto de datos utilizado para el entrenamiento. Esto permitirá al modelo aprender patrones más representativos y mejorar su capacidad para detectar diferentes variaciones y características del carcinoma basocelular en diversas poblaciones y grupos étnicos.

Además, se recomienda explorar otros tipos de arquitecturas de redes neuronales, como redes recurrentes o redes neuronales generativas, para mejorar aún más la precisión del modelo. Estas arquitecturas pueden capturar relaciones temporales o generar datos sintéticos adicionales para el entrenamiento del modelo.

REFERENCIAS BIBLIOGRÁFICAS

- [1] Abunadi, I., & Senan, E. M. (2021). Deep Learning and Machine Learning Techniques of Diagnosis Dermoscopy Images for Early Detection of Skin Diseases. *Electronics*, 10(24), 3158. <https://doi.org/10.3390/electronics10243158>
- [2] Esteva, A., Kuprel, B., Novoa, R. et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 542, 115–118 (2017). <https://doi.org/10.1038/nature21056>
- [3] Höhn J, Hekler A, Krieghoff-Henning E, Kather JN, Utikal JS, Meier F, Gellrich FF, Hauschild A, French L, Schlager JG, Ghoreschi K, Wilhelm T, Kutzner H, Heppt M, Haferkamp S, Sondermann W, Schadendorf D, Schilling B, Maron RC, Schmitt M, Jutzi T, Fröhling S, Lipka DB, Brinker TJ. Integrating Patient Data Into Skin Cancer Classification Using Convolutional Neural Networks: Systematic Review. *J Med Internet Res*. 2021 Jul 2;23(7):e20708. DOI: 10.2196/20708. PMID: 34255646; PMCID: PMC8285747.
- [4] Tahir, M., Naeem, A., Malik, H., Tanveer, J., Naqvi, R. A., & Lee, S.-W. (2023). DSCC_Net: Multi-Classification Deep Learning Models for Diagnosing of Skin Cancer Using Dermoscopic Images. *Cancers*, 15(7), 2179. <https://doi.org/10.3390/cancers15072179>
- [5] Roffman, D., Hart, G., Girardi, M. et al. Predicting non-melanoma skin cancer via a multi-parameterized artificial neural network. *Sci Rep* 8, 1701 (2018). <https://doi.org/10.1038/s41598-018-19907-9>
- [6] Ángeles Rojas, J. A., Calderón Vilca, H. D., Tumi Figueroa, E. N., Cuadros Ramos, K. J., Matos Manguinuri, S. S., & Calderón Vilca, E. F. (2021). Hybrid model of convolutional neural network and support vector machine to classify basal cell carcinoma. *Computación y Sistemas*, 25(1), 83-95. <https://doi.org/10.13053/cys-25-1-3431>
- [7] Yacob, F., Siarov, J., Villiamsson, K. et al. Weakly supervised detection and classification of basal cell carcinoma using graph-transformer on whole slide images. *Sci Rep* 13, 7555 (2023). <https://doi.org/10.1038/s41598-023-33863-z>
- [8] Mansouri, N., Balvay, D., Zenteno, O., Facchin, C., Yoganathan, T., Viel, T., Herraiz, J. L., et al. (2023). Machine Learning of

- Multi-Modal Tumor Imaging Reveals Trajectories of Response to Precision Treatment. *Cancers*, 15(6), 1751. MDPI AG. <http://dx.doi.org/10.3390/cancers15061751>
- [9] Mandal, A., Priyam, S., Chan, H. H., Gouveia, B. M., Guitera, P., Song, Y., Baker, M. A. B., et al. (2023). Computer-Aided Diagnosis of Melanoma Subtypes Using Reflectance Confocal Images. *Cancers*, 15(5), 1428. MDPI AG. <http://dx.doi.org/10.3390/cancers15051428>
- [10] Balaji, P., Muniasamy, V., Bilfaqih, S. M., Muniasamy, A., Tharanidharan, S., Mani, D., & Alsaid, L. E. G. (2023). Chimp Optimization Algorithm Influenced Type-2 Intuitionistic Fuzzy C-Means Clustering-Based Breast Cancer Detection System. *Cancers*, 15(4), 1131. MDPI AG. <http://dx.doi.org/10.3390/cancers15041131>
- [11] Gui, H., Su, T., Pang, Z., Jiao, H., Xiong, L., Jiang, X., Li, L., et al. (2022). Diagnosis of Breast Cancer with Strongly Supervised Deep Learning Neural Network. *Electronics*, 11(19), 3003. MDPI AG. <http://dx.doi.org/10.3390/electronics11193003>
- [12] Kourou, K., Exarchos, T. P., Exarchos, K. P., Karamouzis, M. V., & Fotiadis, D. I. (2015). Machine learning applications in cancer prognosis and prediction. *Computational and structural biotechnology journal*, 13, 8-17. <https://doi.org/10.1016/j.csbj.2014.11.005>
- [13] Li, H., Wang, F., & Huang, W. (2022). A Novel, Simple, and Low-Cost Approach for Machine Learning Screening of Kidney Cancer: An Eight-Indicator Blood Test Panel with Predictive Value for Early Diagnosis. *Current Oncology*, 29(12), 9135–9149. MDPI AG. <http://dx.doi.org/10.3390/curroncol29120715>
- [14] Mahmud, S., Abbas, T. O., Mushtak, A., Prithula, J., & Chowdhury, M. E. H. (2023). Kidney Cancer Diagnosis and Surgery Selection by Machine Learning from CT Scans Combined with Clinical Metadata. *Cancers*, 15(12), 3189. MDPI AG. <http://dx.doi.org/10.3390/cancers15123189>
- [15] Razavi, E., Roth, P., Lang, S., Zimmermann, H., & Dermatoscopy Research Group (2020). Artificial neural networks and pathologists recognize basal cell carcinomas based on different histological patterns. *Modern Pathology*, 34(5), 895-903. <https://doi.org/10.1038/s41379-020-00712-7>
- [16] Gomathi, E., Jayasheela, M., Thamarai, M., & Geetha, M. (2023). Skin cancer detection using dual optimization based deep learning network. *Biomedical Signal Processing and Control*, 84, 104968. DOI: <https://doi.org/10.1016/j.bspc.2023.104968>
- [17] Monika, M. K., Vignesh, N. A., Kumari, C. U., Kumar, M. N. V. S. S., & Lydia, E. L. (2020). Skin cancer detection and classification using machine learning. *Materials Today: Proceedings*, 33, 4266-4270. DOI: <https://doi.org/10.1016/j.matpr.2020.07.366>
- [18] Gibiansky, A. (2014) Convolutional Neural Networks. Andrew Gibiansky. [https://andrew.gibiansky.com/blog/machine-learning/convolutional-neural-networks/#:~:text=In%20order%20to%20compute%20the,\(j%20Bb\).&text=Then%20the%20convolutional%20layer%20applies,\(x%E2%84%93ij\)](https://andrew.gibiansky.com/blog/machine-learning/convolutional-neural-networks/#:~:text=In%20order%20to%20compute%20the,(j%20Bb).&text=Then%20the%20convolutional%20layer%20applies,(x%E2%84%93ij))
- [19] Zhu, P. (2022, January). Convolutional neural networks based study and application for multicategory skin cancer detection. In 2022 3rd International Conference on Electronic Communication and Artificial Intelligence (IWECAL) (pp. 558-561). IEEE.
- [20] Abhiram, A. P., Anzar, S. M., & Panthakkan, A. (2022, December). DeepSkinNet: A Deep Learning Model for Skin Cancer Detection. In 2022 5th International Conference on Signal Processing and Information Security (ICSPIS) (pp. 97-102). IEEE.