



PREPROCESAMIENTO Y ANÁLISIS COMPARATIVO DE IMÁGENES DERMATOSCÓPICAS DE LESIONES CUTÁNEAS BENIGNAS Y MALIGNAS USANDO HERRAMIENTAS DE PYTHON

PREPROCESSING AND COMPARATIVE ANALYSIS OF DERMATOSCOPIC IMAGES OF BENIGN AND MALIGNANT SKIN LESIONS USING PYTHON TOOLS

Valeska López Salinas^{a*}

^aEstudiante de Medicina, Facultad de Medicina Clínica Alemana - Universidad del Desarrollo, Santiago, Chile.
Artículo recibido el 9 de mayo, 2025. Aceptado en versión corregida el 28 de octubre, 2025.

DOI: 10.52611/confluencia.2025.1238

RESUMEN

Introducción: El diagnóstico temprano de cáncer de piel requiere bases de datos de calidad. Avances en IA mejoran precisión, pero aún enfrentan desafíos en almacenamiento, representación y evaluación objetiva de imágenes dermatológicas. **Objetivo:** Explorar la utilización de metodologías cuantitativas de procesamiento y análisis de imágenes digitales para categorizar lesiones cutáneas, evaluando la idoneidad de la base de datos para su uso en modelos de entrenamiento. **Metodología:** Investigación exploratoria y descriptiva en la que se recopilaron y procesaron imágenes dermatoscópicas de lesiones benignas y malignas, empleando técnicas de segmentación, extracción de características y análisis estadístico mediante el desarrollo de código ejecutable en Python y librerías especializadas. **Resultado:** Se evidencian diferencias entre las imágenes de lesiones benignas y malignas. Las lesiones benignas presentan valores más elevados y homogéneos en los canales de color rojo, verde y azul, así como un brillo promedio superior y un contraste menor. Las lesiones malignas muestran mayor variabilidad cromática, menor brillo, mayor contraste y una textura más compleja. **Discusión:** Los resultados coinciden con hallazgos previamente descritos en la literatura, donde se observaron diferencias significativas de contraste entre lesiones malignas vs benignas y presencia de mayor heterogeneidad cromática en imágenes malignas. **Conclusión:** los resultados obtenidos refuerzan la importancia del análisis cuantitativo y automatizado en la evaluación de imágenes médicas, aportando objetividad y reproducibilidad al análisis de datos complejos. La identificación de patrones diferenciadores en color y textura permite identificar tipos de lesiones.

Palabras clave: Cáncer de piel; Imágenes médicas; Diagnóstico por imagen; Aprendizaje automático.

ABSTRACT

Introduction: Early diagnosis of skin cancer requires high-quality databases. Advances in AI improve accuracy, but challenges remain in the storage, representation, and objective evaluation of dermatological images. **Objective:** To explore the use of quantitative digital image processing and analysis methodologies to categorize skin lesions, evaluating the suitability of the database for use in training models. **Methodology:** Exploratory and descriptive research in which dermatoscopic images of benign and malignant lesions were collected and processed, using segmentation techniques, feature extraction, and statistical analysis through the development of executable code in Python and specialized libraries. **Result:** Differences between images of benign and malignant lesions were evident. Benign lesions had higher and more homogeneous values in the red, green, and blue color channels, as well as higher average brightness and lower contrast. Malignant lesions show greater color variability, lower brightness, higher contrast, and a more complex texture. **Discussion:** The results are consistent with findings previously described in the literature, where significant differences in contrast between malignant and benign lesions and greater color heterogeneity in malignant images were observed. **Conclusion:** The results obtained reinforce the importance of quantitative and automated analysis in the evaluation of medical images, providing objectivity and reproducibility to the analysis of complex data. The identification of differentiating patterns in color and texture allows the identification of lesion types.

Key words: Skin cancer; Medical imaging; Diagnostic imaging; Machine learning.

Cómo citar:

López-Salinas V. Preprocesamiento y análisis comparativo de imágenes dermatoscópicas de lesiones cutáneas benignas y malignas usando herramientas de Python. Rev Conflu [Internet]. 2025 [citado el 31 de octubre 2025];8. Disponible en: <https://doi.org/10.52611/confluencia.2025.1368>

INTRODUCCIÓN

El cáncer de piel constituye uno de los principales desafíos en la dermatología moderna. Dada la creciente incidencia, secundaria al envejecimiento poblacional y exposición a rayos UV, se hace necesario un diagnóstico temprano para mejorar el pronóstico de los pacientes¹.

Esta investigación surge de la necesidad de optimizar el diagnóstico temprano del cáncer de piel mediante herramientas objetivas y reproducibles. Para que esto ocurra lo primero es analizar la idoneidad de la base de datos a utilizar, a través de un enfoque exploratorio descriptivo y, al menos en esta etapa de la investigación, no se orientará a producir un modelo predictivo. Esta motivación se fundamenta principalmente al identificar, tanto a nivel nacional como internacional, deficiencias en el almacenamiento y procesamiento de imágenes dermatoscópicas. Los métodos convencionales presentan limitaciones claras, ya que dependen en gran medida de la apreciación clínica subjetiva, lo que puede afectar la precisión y reproducibilidad del diagnóstico, en especial en pieles oscuras².

En la última década, el avance en tecnologías de procesamiento de imágenes, inteligencia artificial y aprendizaje profundo ha revolucionado el diagnóstico dermatológico³, permitiendo la extracción y análisis de características objetivas de las lesiones cutáneas⁴⁻⁶. El uso de Redes Neuronales Convolucionales (CNN por su sigla en inglés), Transformadores de Visión (ViT en inglés) y técnicas de aumento de datos, ha demostrado mejoras significativas en la precisión y eficiencia de la clasificación de lesiones, incluso en algunas circunstancias superando las limitaciones de la evaluación clínica tradicional y la dermatoscopia manual⁷⁻⁹. Sin embargo, la calidad, representatividad y adecuación de las bases de datos de imágenes constituyen un desafío clave para el desarrollo de modelos robustos y generalizables¹⁰.

El estado del arte evidencia que la mayoría de los estudios se centran en los modelos de clasificación automática de imágenes, pero pocos abordan el preprocesamiento y la evaluación cuantitativa de la base de datos como paso previo fundamental para garantizar la validez del entrenamiento¹⁰. Además, la literatura destaca la importancia de analizar la variabilidad de las imágenes, la preservación de características relevantes y la representatividad de las muestras en relación con la epidemiología local¹¹.

La pregunta de investigación que guía este estudio se plantea de la siguiente manera: ¿es adecuada la base de datos de imágenes de lesiones cutáneas para ser utilizada en el entrenamiento de modelos de clasificación automática, considerando un enfoque exploratorio descriptivo de sus características? La hipótesis plantea que el análisis cuantitativo de métricas de color y textura en imágenes dermatoscópicas permite identificar diferencias sistemáticas entre lesiones benignas y

malignas, y detectar posibles sesgos de la base de datos que condicionen su idoneidad para entrenar futuros modelos de clasificación.

Como objetivo general explora la utilización de metodologías cuantitativas de procesamiento y análisis de imágenes digitales para categorizar lesiones cutáneas, evaluando la idoneidad de la base de datos para su uso en modelos de entrenamiento. Del mismo modo, los objetivos específicos propuestos son: a) analizar las características estadísticas y texturales de las imágenes de lesiones cutáneas benignas y malignas; b) comparar la distribución de parámetros relevantes entre ambas categorías; c) identificar posibles sesgos o deficiencias en la base de datos y, finalmente, d) proponer criterios de inclusión y exclusión de imágenes para optimizar futuros entrenamientos.

El artículo se organiza en cinco secciones: introducción, metodología, resultados, discusión y conclusiones. La metodología empleada es exploratoria descriptiva, basada en el procesamiento digital de imágenes, extracción de características y análisis estadístico descriptivo y comparativo.

METODOLOGÍA

Diseño del estudio

Se seleccionó un diseño cuantitativo, de tipo exploratorio descriptivo y comparativo, coherente con la pregunta de investigación que busca evaluar la idoneidad de una base de datos de imágenes dermatoscópicas como paso previo al desarrollo de modelos predictivos.

Universo, muestra y unidad de análisis

El universo está constituido por imágenes digitales de lesiones cutáneas benignas y malignas. La muestra se extrajo de la base de datos pública “*Skin Cancer: Malignant vs. Benign*” *Processed Skin Cancer Pictures of the ISIC Archive*, disponible en la plataforma Kaggle y desarrollada por The International Skin Imaging Collaboration (ISIC)¹². Esta base contiene imágenes de alta calidad, clasificadas clínicamente, y es ampliamente utilizada en investigaciones internacionales sobre cáncer de piel. La unidad de análisis corresponde a cada imagen individual de lesión cutánea.

Técnica de muestreo

Se empleó un muestreo no probabilístico de tipo intencionado, seleccionando imágenes que cumplieran con criterios de calidad y representatividad para ambas categorías (benignas y malignas). Esta técnica fue elegida para asegurar la inclusión de casos relevantes y comparables, acorde a los objetivos del estudio.

Población participante y criterios de selección

La población participante está conformada por imágenes de lesiones cutáneas, sin involucrar

directamente a personas. Los criterios de inclusión fueron: imágenes en formato digital, alta resolución, y clasificación clínica previa como lesión benigna o maligna. Se excluyeron imágenes con baja calidad, artefactos, o información incompleta respecto a su diagnóstico.

Variables a estudiar

Las variables principales analizadas incluyen:

- Intensidad de color
- Parámetros de textura
- Parámetros de forma
- Clasificación clínica (benigna/maligna)

Instrumentos y sus características

El procesamiento y análisis de las imágenes se realizó mediante un código computacional implementado en Python. Para el desarrollo y documentación del análisis se utilizó Jupyter Notebook (versión 7.2.2), lo que permitió un flujo de trabajo interactivo y reproducible. El entorno de desarrollo se gestionó con Conda (versión 24.11.3) para asegurar la correcta administración de dependencias y entornos virtuales. El código fue editado y ejecutado en Visual Studio Code (versión 1.99.1), aprovechando su integración con Jupyter Notebook. El procesamiento se llevó a cabo en un equipo con procesador Apple M2 Max, 32 GB de memoria RAM y sistema operativo macOS 15.4, lo que garantizó la eficiencia y estabilidad en el manejo de grandes volúmenes de datos.

El protocolo de análisis incluyó módulos de extracción de métricas de color (medias y Desviaciones Estándar (DE) por canal RGB), brillo, contraste, entropía y contraste de textura (Gray Level Co-occurrence Matrix o GLCM). Las texturas se extrajeron sobre imágenes convertidas a escala de grises (luminosidad) cuantizadas a 256 niveles. Se calcularon matrices GLCM con distancias $d = \{1, 2, 4\}$ y ángulos $\{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$; las métricas (contraste, entropía) se promediaron entre ángulos y distancias. Para color, se usó RGB (Red, Green, Blue por su nombre en inglés) normalizado a $[0, 1]$.

Plan de análisis de datos

El análisis de datos contempló estadística descriptiva y comparativa, para explorar patrones por categoría. Las distribuciones se evaluaron con Shapiro-Wilk (n aleatorio ≤ 500 por grupo). Dada la no-normalidad ($p < 0,05$), se aplicó Mann-Whitney U (bilateral), con corrección por comparaciones múltiples (FDR por su sigla en inglés). Se reportan tamaños del efecto (*Cliff's delta*) y IC95% para las diferencias de medianas.

Consideraciones éticas

El estudio se realizó en apego a las normativas nacionales e internacionales en materia de ética en investigación. Dado que se trabajó exclusivamente

con imágenes anonimizadas y sin información personal identificable, no fue necesario obtener consentimiento informado individual. Los datos están dispuestos en una base de acceso pública, por lo que no se requirió de aprobación de un comité de ética institucional ni cartas para su uso.

RESULTADO

Caracterización y distribución de la base de datos

La base de datos quedó compuesta por 3297 imágenes clasificadas en dos categorías: 1800 benignas y 1497 malignas, distribuidas en conjuntos de entrenamiento y prueba (Tabla 1), todas en formato RGB y con una resolución de 224 x 224 píxeles. La distribución de clases presenta un desbalance moderado (55% / 45%).

Tabla 1. Distribución de las imágenes en la base de datos utilizada para el análisis.

Categoría	Test	Train	Total
Malignas	360	1440	1800
Benignas	360	1197	1497
Total	660	2637	3297

Preprocesamiento y estandarización

Todas las imágenes fueron convertidas a formato RGB y normalizadas a 224 x 224 píxeles para asegurar la consistencia en el análisis. Se etiquetaron las imágenes: 0 para benignas y 1 para malignas. Los datos fueron aleatorizados (*shuffle*) antes de su uso en análisis y modelado, garantizando la validez estadística de los resultados.

Se realizó una visualización exploratoria de una muestra representativa de imágenes de ambas categorías, empleando funciones de visualización en Python (Figura 1). Esta inspección permitió identificar visualmente la distribución espacial y cromática de las lesiones, validar la correcta asignación de etiquetas y asegurar la adecuación de las imágenes para el análisis posterior.

Análisis descriptivo y estadístico

En el marco del análisis cuantitativo realizado sobre la base de datos de imágenes de lesiones cutáneas benignas y malignas, se calcularon diversas métricas estadísticas fundamentales para cada imagen, con el objetivo de identificar diferencias relevantes entre ambas categorías y aportar evidencia objetiva al proceso de clasificación automatizada.

En primer lugar, se determinaron las medias y DE de los canales de color rojo (R), verde (G) y azul (B) para cada grupo. Las imágenes benignas presentaron medias de intensidad más elevadas y homogéneas en los tres canales (Mean_R = $0,83 \pm 0,06$; Mean_G = $0,53 \pm 0,09$; Mean_B = $0,56 \pm 0,12$), mientras que las imágenes malignas exhibieron valores más bajos y dispersos (Mean_R = $0,74 \pm 0,21$; Mean_G = $0,45 \pm 0,20$; Mean_B = $0,38 \pm 0,19$).




Figura 1. Visualización de imágenes dermatoscópicas de la base de datos “Skin Cancer: Malignant vs. Benign” proveniente del archivo procesado del ISIC Archive con sus respectivas etiquetas. Elaboración propia.

Esta mayor variabilidad en las lesiones malignas también se reflejó en las DE de cada canal, indicando una mayor heterogeneidad cromática en este grupo (Tabla 2).

Tabla 2. Comparación de métricas estadísticas y texturales en imágenes dermatoscópicas de lesiones cutáneas benignas y malignas.

Métrica	Benignas (Media ± DE)	Malignas (Media ± DE)
Mean_R	0,83 ± 0,06	0,74 ± 0,21
Mean_G	0,53 ± 0,09	0,45 ± 0,20
Mean_B	0,56 ± 0,12	0,38 ± 0,19
Brillo	0,64 ± 0,07	0,52 ± 0,10
Contraste	0,12 ± 0,03	0,19 ± 0,06
Entropía	7,07 ± 0,12	7,03 ± 0,15
Textura_Contraste (GLCM)	120 ± 60	438 ± 150

El brillo promedio, calculado como la media de todos los píxeles de la imagen, fue superior en las lesiones benignas ($0,64 \pm 0,07$) respecto a las malignas ($0,52 \pm 0,10$), lo que sugiere una mayor uniformidad lumínica en las primeras. Por otro lado, el contraste general, medido como la DE global de la imagen, resultó mayor en las imágenes malignas ($0,19 \pm 0,06$) en comparación con las benignas ($0,12 \pm 0,03$), reflejando una mayor presencia de zonas con diferencias marcadas de intensidad en las lesiones malignas.

En cuanto a las métricas de textura, se analizaron la entropía y el contraste de textura mediante la matriz

GLCM. La entropía, que mide la complejidad de la imagen, fue ligeramente mayor en benignas ($7,07 \pm 0,12$ vs $7,03 \pm 0,15$), diferencia pequeña pero significativa. Sin embargo, el contraste de textura (GLCM) mostró una diferencia marcada: las imágenes malignas alcanzaron valores promedio de 438 ± 150 , mientras que las benignas presentaron valores considerablemente menores (120 ± 60). Este hallazgo indica que las lesiones malignas tienden a exhibir patrones visuales más irregulares y caóticos, en contraste con la mayor uniformidad de las benignas.

En síntesis, el análisis estadístico evidencia que las imágenes benignas tienden a ser más homogéneas en términos de color y brillo, mientras que las malignas presentan mayor variabilidad cromática, menor brillo, mayor contraste y una textura más compleja e irregular (Figura 2).

Por otra parte, el análisis mediante la prueba no paramétrica de Mann-Whitney U evidenció diferencias estadísticamente significativas ($p < 0,05$) entre las lesiones benignas y malignas en todas las variables evaluadas: Mean_R ($p = 6,69 \times 10^{-152}$), Mean_G ($p = 3,57 \times 10^{-4}$), Mean_B ($p = 1,47 \times 10^{-8}$), Brillo ($p = 1,08 \times 10^{-31}$), Contraste ($p = 6,95 \times 10^{-31}$), Entropía ($p = 1,05 \times 10^{-6}$) y Textura_Contraste ($p = 1,39 \times 10^{-154}$). En conjunto, estos resultados sugieren que las lesiones malignas tienden a presentar un brillo promedio menor, un contraste más elevado y una textura más irregular en comparación con las lesiones benignas.




Figura 2. Boxplot comparativo de métricas de color, brillo, contraste, entropía y textura en imágenes dermatoscópicas de lesiones benignas y malignas.

DISCUSIÓN

Los resultados del análisis estadístico y textural evidencian diferencias entre las imágenes de lesiones benignas y malignas. Las lesiones benignas presentan valores más elevados y homogéneos en los canales de color rojo, verde y azul, así como un brillo promedio superior y un contraste menor. Por el contrario, las lesiones malignas muestran mayor variabilidad cromática, menor brillo, mayor contraste y una textura más compleja. Esto es resultado de una arquitectura visual más desorganizada, lo que es coherente con la fisiopatología de las neoplasias cutáneas, caracterizadas por crecimiento desordenado y heterogeneidad celular.

Estos resultados coinciden con hallazgos previamente descritos en la literatura, donde se observaron diferencias significativas de contraste entre lesiones malignas vs benignas¹³ y presencia de mayor heterogeneidad cromática en imágenes malignas¹⁴.

Estas comparaciones refuerzan la validez del presente estudio exploratorio descriptivo y respaldan la hipótesis, dado que se logró identificar características predominantes en las imágenes según su categoría, además de establecer que existe desequilibrio de clases moderado. Esto resulta imprescindible de ser detectado previo al entrenamiento del modelo, ya que puede afectar la capacidad predictiva, para lo cual existen algunas estrategias para solucionar este problema, tal como técnicas de sobremuestreo¹⁵.

El presente estudio se limitó a explorar imágenes, lo que limita la extrapolación de los resultados a un

contexto diagnóstico automático. Futuras investigaciones deberían incorporar información clínica y/o histopatológica, para confirmar la aplicabilidad de estos hallazgos en un entorno real.

CONCLUSIÓN

La investigación cuantitativa desarrollada logró plenamente los objetivos planteados, descritos como analizar y comparar características estadísticas y texturales de imágenes dermatoscópicas de lesiones cutáneas benignas y malignas, utilizando herramientas de procesamiento digital. La principal conclusión es que esta base de datos debe ajustarse previo a ser utilizada para entrenamiento automatizado, debido que presenta un desequilibrio de clases. Al analizar los grupos de imágenes, entre los resultados más relevantes, se identificó que las lesiones benignas presentan mayor homogeneidad en brillo e intensidad de color, así como menor variabilidad y contraste, lo que se traduce en una textura más uniforme. Por el contrario, las lesiones malignas exhiben mayor heterogeneidad cromática, menor brillo, mayor contraste y una textura más compleja e irregular. Estas diferencias se observaron de manera consistente en las métricas analizadas, y son coherentes con la evidencia revisada y los patrones clínicos reconocidos en dermatología.

Este trabajo representa una contribución relevante para la formación en pregrado, ya que permitió integrar conocimientos de procesamiento de datos, análisis estadístico y fundamentos de inteligencia artificial aplicados a problemas médicos reales. La experiencia adquirida fortalece competencias

técnicas fundamentales para la medicina moderna, como la interpretación crítica de métricas objetivas y la comprensión de que el sustento de un modelo de aprendizaje automático es necesario para disponer de una adecuada base de datos.

Desde la perspectiva disciplinar, los resultados obtenidos refuerzan la importancia del análisis cuantitativo y automatizado en la evaluación de imágenes médicas, aportando objetividad y reproducibilidad al análisis de datos complejos. La identificación de patrones diferenciadores en color y textura permite identificar distintos tipos de lesiones.

El estudio presenta algunas limitaciones. La base de datos utilizada presenta un desbalance moderado, corresponde a imágenes internacionales y podría no reflejar completamente la diversidad epidemiológica local. Además, el análisis se centró en parámetros estadísticos y texturales, sin incorporar información clínica adicional o validación histopatológica. Estos vacíos abren nuevas líneas de investigación, como la integración de datos clínicos y la validación en poblaciones locales, así como la exploración de otras modalidades diagnósticas y el perfeccionamiento de los modelos predictivos.

REFERENCIAS BIBLIOGRÁFICAS

1. Brochez L, Volkmer B, Hoorens I, Garbe C, Röcken M, Schütz J, et al. Skin cancer in Europe today and challenges for tomorrow. *J Eur Acad Dermatol Venerol* [Internet]. 2025 [citado el 19 de abril 2025];39(2):272-7. Disponible en: <https://doi.org/10.1111/jdv.20368>
2. Krefting F, Moelleken M, Hölsken S, Placke JM, Eisenburger RT, Albrecht LJ, et al. Comparison of visual diagnostic accuracy of dermatologists practicing in Germany in patients with light skin and skin of color. *Sci Rep* [Internet]. 2024 [citado el 19 de abril 2025];14(1):8740. Disponible en: <https://doi.org/10.1038/s41598-024-59426-4>
3. Li Z, Koban KC, Schenck TL, Giunta RE, Li Q, Sun Y. Artificial Intelligence in Dermatology Image Analysis: Current Developments and Future Trends. *J Clin Med* [Internet]. 2022 [citado el 19 de abril 2025];11(22):6826. Disponible en: <https://doi.org/10.3390/jcm11226826>
4. Ray A, Sarkar S, Schwenker F, Sarkar R. Decoding skin cancer classification: perspectives, insights, and advances through researchers' lens. *Sci Rep* [Internet]. 2024 [citado el 19 de abril 2025];14(1):30542. Disponible en: <https://doi.org/10.1038/s41598-024-81961-3>
5. Stafford H, Buell J, Chiang E, Ramesh U, Migden M, Nagarajan P, et al. Non-Melanoma Skin Cancer Detection in the Age of Advanced Technology: A Review. *Cancers (Basel)* [Internet]. 2023 [citado el 19 de abril 2025];15(12):3094. Disponible en: <https://doi.org/10.3390/cancers15123094>
6. Giavina-Bianchi M, de Sousa RM, Paciello VZA, Vitor WG, Okita AL, Prôa R, et al. Implementation of artificial intelligence algorithms for melanoma screening in a primary care setting. *PLoS One* [Internet]. 2021 [citado el 19 de abril 2025];16(9):e0257006. Disponible en: <https://doi.org/10.1371/journal.pone.0257006>
7. Ba W, Wu H, Chen WW, Wang SH, Zhang ZY, Wei XJ, et al. Convolutional neural network assistance significantly improves dermatologists' diagnosis of cutaneous tumours using clinical images. *Eur J Cancer* [Internet]. 2022 [citado el 19 de abril 2025];169:156-65. Disponible en: <https://doi.org/10.1016/j.ejca.2022.04.015>
8. Khan S, Khan A. SkinViT: A transformer based method for Melanoma and Nonmelanoma classification. *PLoS One* [Internet]. 2023 [citado el 19 de abril 2025];18(12):e0295151. Disponible en: <https://doi.org/10.1371/journal.pone.0295151>
9. Chen L, Li J, Zou Y, Wang T. ETU-Net: edge enhancement-guided U-Net with transformer for skin lesion segmentation. *Phys Med Biol* [Internet]. 2023 [citado el 19 de abril 2025];69(1). Disponible en: <https://doi.org/10.1088/1361-6560/ad13d2>
10. Niño-Rondón CV, Forero-Vargas MG, Castro-Casadiegos SA. Transformaciones geométricas vs Inducción de ruido: Comparación de técnicas de aumentado de datos para análisis de imágenes dermoscópicas. *Respuestas* [Internet]. 2023 [citado el 19 de abril 2025];28(3):48-57. Disponible en: <https://doi.org/10.22463/0122820X.4276>
11. Mohammed S, Budach L, Feuerpfeil M, Ihde N, Nathansen A, Noack N, et al. The Effects of Data Quality on Machine Learning Performance on Tabular Data [Internet]. USA: arXiv:2207.14529 Cornell University; 2022 [citado el 19 de abril 2025]. Disponible en: <https://doi.org/10.48550/arXiv.2207.14529>
12. Fanconi C. Skin Cancer: Malignant vs Benign. Processed Skin Cancer pictures of the ISIC Archive [Internet]. 2019 [citado el 19 de abril 2025]. Disponible en: <https://www.kaggle.com/fanconic/skin-cancer-malignant-vs-benign>
13. Sabir R, Mehmood T. Classification of melanoma skin Cancer based on Image Data Set using different neural networks. *Sci Rep* [Internet]. 2024 [citado el 19 de abril 2025];14(1):29704. Disponible en: <https://doi.org/10.1038/s41598-024-75143-4>
14. Dębicka-Kumela M, Romanowska-Dixon B, Karska-Basta I, Kowal J, Markiewicz A. The Evaluation of the Malignant Characteristics of Conjunctival Lesions Based on the Dermatoscopic Algorithm. *Anticancer Res* [Internet]. 2021 [citado el 19 de abril 2025];41(2):895-903. Disponible en: <https://doi.org/10.21873/anticancer.14842>
15. Buda M, Maki A, Mazurowski MA. A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks* [Internet]. 2018 [citado el 19 de abril 2025];106:249-59. Disponible en: <https://doi.org/10.48550/arXiv.2207.14529>