



Librerías informáticas utilizadas en análisis de imágenes dermatológicas con visión computacional: una revisión de literatura

Computer libraries used in analysis of dermatological images with computational vision: a literature review

Huanatico-Lipa, Jose Carlos^{1*}

Coral-Ygnacio, Marco Antonio¹

¹Universidad Católica Sedes Sapientiae, Lima, Perú

Recibido: 08 Jul. 2023 | **Aceptado:** 12 Oct. 2023 | **Publicado:** 10 Ene. 2024

Autor de correspondencia*: 2017100417@ucss.pe

Como citar este artículo: Huanatico-Lipa, J. C. & Coral-Ygnacio, M. A. (2024). Librerías informáticas utilizadas en análisis de imágenes dermatológicas con visión computacional. Una revisión de literatura. *Revista Científica de Sistemas e Informática*, 4(1), e590. <https://doi.org/10.51252/rcsi.v4i1.590>

RESUMEN

El análisis de imágenes cutáneas desempeña un papel fundamental en el ámbito de la dermatología, ya que posibilita la detección temprana y precisa de diversas afecciones de la piel. No obstante, este proceso se enfrenta a desafíos significativos debido a la variabilidad de características presentes en las lesiones cutáneas, tales como texturas, tonalidades y la existencia de vellosidades en el contorno. En este artículo, se presenta una revisión sistemática de literatura sobre librerías informáticas utilizadas en el análisis de imágenes dermatológicas con visión computacional. Esta investigación se basa en la declaración PRISMA y las bases de datos científicas: SCOPUS e IEEE Xplore para la búsqueda y tiene como objetivo identificar una amplia variedad de librerías informáticas y lesiones cutáneas. Los resultados mostraron 7 librerías y 21 lesiones dermatológicas, que contribuyen a un análisis más preciso y a un diagnóstico clínico más fiable para la detección oportuna de trastornos cutáneos. En conclusión, la presente investigación resalta librerías informáticas que tiene un impacto significativo en la mejora del diagnóstico clínico, lo cual es clave para el desarrollo de soluciones efectivas para la salud de las personas.

Palabras clave: clasificación dermatológica; diagnóstico clínico; inteligencia artificial; lesiones cutáneas; procesamiento de imágenes; segmentación de piel

ABSTRACT

Skin image analysis plays a fundamental role in the field of dermatology, as it enables early and accurate detection of various skin conditions. However, this process faces significant challenges due to the variability of characteristics present in skin lesions, such as textures, tones, and the existence of villi on the contour. In this article, a systematic review of literature on computer libraries used in the analysis of dermatological images with computer vision is presented. This research is based on the PRISMA statement and scientific databases: SCOPUS and IEEE Xplore for searching and aims to identify a wide variety of computer libraries and skin lesions. The results showed 7 libraries and 21 dermatological lesions, which contribute to a more precise analysis and a more reliable clinical diagnosis for the timely detection of skin disorders. In conclusion, this research highlights computer libraries that have a significant impact on improving clinical diagnosis, which is key to the development of effective solutions for people's health.

Keywords: dermatological classification; clinical diagnosis; artificial intelligence; skin lesions; image processing; skin segmentation



1. INTRODUCCIÓN

El análisis de imágenes dermatológicas (AID) se ha convertido en un proceso esencial en el campo de la dermatología puesto que permite a los especialistas tener un enfoque preciso y objetivo en el seguimiento y diagnóstico de trastornos cutáneos. De este modo, los sistemas que adoptan el AID proporcionan un procesamiento y una evaluación precisa de las características de las lesiones dermatológicas. Por ello, las librerías informáticas cobran relevancia para garantizar la precisión y eficiencia en la detección de trastornos dermatológicos.

En los últimos años, las implementaciones de AID han experimentado varios enfoques de desarrollo que se han basado en modelos de inteligencia artificial como FCN, U-Net y SegNet, las cuales permiten que los sistemas puedan extraer y segmentar la información de las imágenes de modo que se logre un eficiente análisis (Lou et al., 2023). A pesar de que las implementaciones se basaban en estos enfoques sofisticados, las pruebas demostraron que existían deficiencias en su rendimiento y performance. Esto porque se evidenció la presencia de factores que los sistemas no consideraban en su proceso como es la diversidad racial, tipologías de piel y la presencia de elementos externos, por ello se tuvo que añadir como elemento de cambio dichos factores para poder lograr un mayor rendimiento y precisión que garantice la eficiencia en las implementaciones de sistemas de AID (Phan et al., 2023; Yilmaz & Trocan, 2021).

Para la recopilación de información de las lesiones cutáneas en implementaciones actuales, los dermatólogos utilizan las imágenes clínicas o dermatoscópicas, las cuales son generadas por medio de cámaras digitales anexas a un sistema de procesamiento para el respectivo análisis dermatológico (Palacios & Díaz, 2017). Si bien este método tradicional contempla la identificación de diferentes trastornos cutáneos, existen parámetros y condiciones que no se consideran, tales como: la iluminación, la calidad de imagen, la variabilidad de distancia y elementos distractores. Esto conlleva que los especialistas realicen esfuerzos adicionales para validar los resultados obtenidos por el sistema con el objetivo de reducir la tasa de error en el diagnóstico (Albraikan et al., 2023). En vista de las limitaciones mencionadas, se debe estudiar las librerías informáticas que permitan el desarrollo de nuevas implementaciones de sistemas AID, asimismo, de lesiones dermatológicas para el estudio de patrones que propicien un eficiente reconocimiento y clasificación de estas en los diagnósticos dermatológicos (Wu et al., 2022).

Los diferentes estudios realizados en el tema muestran una gran variedad de implementaciones basados en modelos, las cuales en su mayoría se centran en modificaciones y uniones de otros modelos existentes, en las cuales se aplican una serie de ajustes que responden a las deficiencias encontradas (Wu et al., 2022; Yao et al., 2022; Zhang et al., 2022). Asimismo, se presenta un conjunto de métodos y técnicas claves que posibilitan el éxito del modelo y de las implementaciones de AID.

A pesar de los diversos estudios analizados en este tema, no se identificaron implementaciones que posean librerías informáticas que otorguen un nivel de precisión mayor al 93,2% y que se adapten a nuevas características que pueden presentar las lesiones cutáneas en un entorno real (Alzubaidi et al., 2022). Por ello, no se determina de manera eficiente la implementación de un sistema de AID. Esto sirve de motivación para realizar una revisión sistemática de literatura que permita contemplar el alcance del factor de precisión y adaptabilidad.

El objetivo de la revisión sistemática de literatura se centra en la identificación de librerías para la implementación de sistemas AID, del mismo modo que se consideran las que son más utilizadas. Asimismo, se identifican las lesiones por visión computacional, en ese sentido se toman en cuenta las que son más complejas de reconocer para identificar patrones que posibiliten la eficiencia del diagnóstico médico.

2. MATERIALES Y MÉTODOS

Se realizó una investigación de tipo descriptiva con un diseño de revisión sistemática de literatura considerando las etapas presentadas por diversos autores en relación a las Tecnologías de la Información

(Liberati et al., 2009; Caballé et al., 2020; Decharatanachart et al., 2021; Islam et al., 2020), de este modo se establecen 11 pasos a seguir: Elaboración del título, resumen estructurado, justificación, objetivos, criterio de elegibilidad, fuentes de información, búsqueda, selección de estudios, procesos de recopilación de datos, síntesis de resultados y conclusiones (Liberati et al., 2009).

La revisión sistemática de literatura se elabora a partir de la declaración PRISMA (Liberati et al., 2009). Asimismo, se considera el cribado y la recolección de datos según la estructura de cuatro pasos (Alcantud Marín et al., 2015). En este proceso se utilizan como fuentes de información las bases de datos SCOPUS e IEEE Xplore por ser consideradas de alta reputación y calidad para temas de investigación.

Para el alcance de los objetivos propuestos, se definieron cuatro preguntas de investigación que serán claves para el estudio.

- i. ¿Qué librerías son utilizadas en implementaciones de sistemas de análisis de imágenes dermatológicas?
- ii. ¿Qué lesiones dermatológicas pueden ser analizadas mediante reconocimiento por visión computacional?
- iii. ¿Cuáles son las lesiones de la piel más complejas de analizar mediante reconocimiento por visión computacional?

Los criterios establecidos para la búsqueda y selección de artículos (inclusión y exclusión) se muestran en la Tabla 1.

Tabla 1.

Criterios de inclusión y exclusión de la RSL

	Criterios	Razones
Inclusión	Unidad de análisis	Estudios que incluyan implementaciones de sistemas de análisis de imágenes dermatológicas y considere imágenes médicas
	Enfoque de Investigación	Estudios que identifiquen modelos, métodos y técnicas en el proceso de análisis de imágenes dermatológicas en Hospitales
	Tipo de Publicación	Artículos en estado final
	Idioma	Solo se consideran artículos en idioma inglés
	Periodo	Enero del 2021 - marzo del 2023
	Área	Ciencias de la computación (Computer Science)
Exclusión	Enfoque de investigación	Estudios que no muestran metodología de investigación, estadísticas descriptivas y análisis o discusión

Las fuentes de información que permitieron la extracción de los estudios fueron: SCOPUS e IEEE Xplore con fecha de corte al 27 de abril del 2023. Se optaron por estas bases de datos científicas, ya que proveen investigaciones de calidad y una notoria reputación respaldada por investigadores e instituciones internacionales destacadas (Cañedo et al., 2010).

Para la extracción de la información en la base de datos se utilizaron las siguientes palabras claves: "methods", "models", "techniques", "image analysis", "computer vision", "visual identification", "image processing", "dermatological", "skin", "lesions", "libraries", "development", "implementation", "software", "system", "application". Con base a estas, se pudo definir la siguiente cadena de búsqueda: ("image analysis" OR "computer vision" OR "visual identification" OR "image processing") AND (dermatological OR skin OR lesions) AND (models OR methods OR techniques) AND (libraries OR development OR implementation) AND (software OR system OR application). La búsqueda se aplicó de igual manera en Scopus como en IEEE Xplore para los estudios respectivos.

La selección de los artículos se llevó a cabo siguiendo un proceso de cribado basado en las etapas detalladas en la Figura 1. Los estudios pertinentes fueron identificados en la etapa de análisis de título y resumen, así como en la revisión exhaustiva de los artículos. En el análisis de título y resumen, se procedió a identificar aquellos artículos que guardarán relación con los objetivos de la investigación, evaluando minuciosamente los títulos y resúmenes. En lo que respecta a la revisión completa, se llevó a cabo un análisis integral de todas las secciones de los artículos con el propósito de confirmar su potencial contribución al tema de investigación.

3. RESULTADOS Y DISCUSIÓN

3.1. Resultados de búsqueda

La búsqueda se llevó a cabo en la primera etapa del cribado, obteniendo un total de 97 400 estudios entre Scopus e IEEE Xplore, en Scopus 921 publicaciones y en IEEE Xplore 93, luego se encontraron 12 trabajos duplicados, los cual dan un total de 1 002 artículos incluidos, luego se filtraron a partir del título y el resumen quedando 62 artículos.

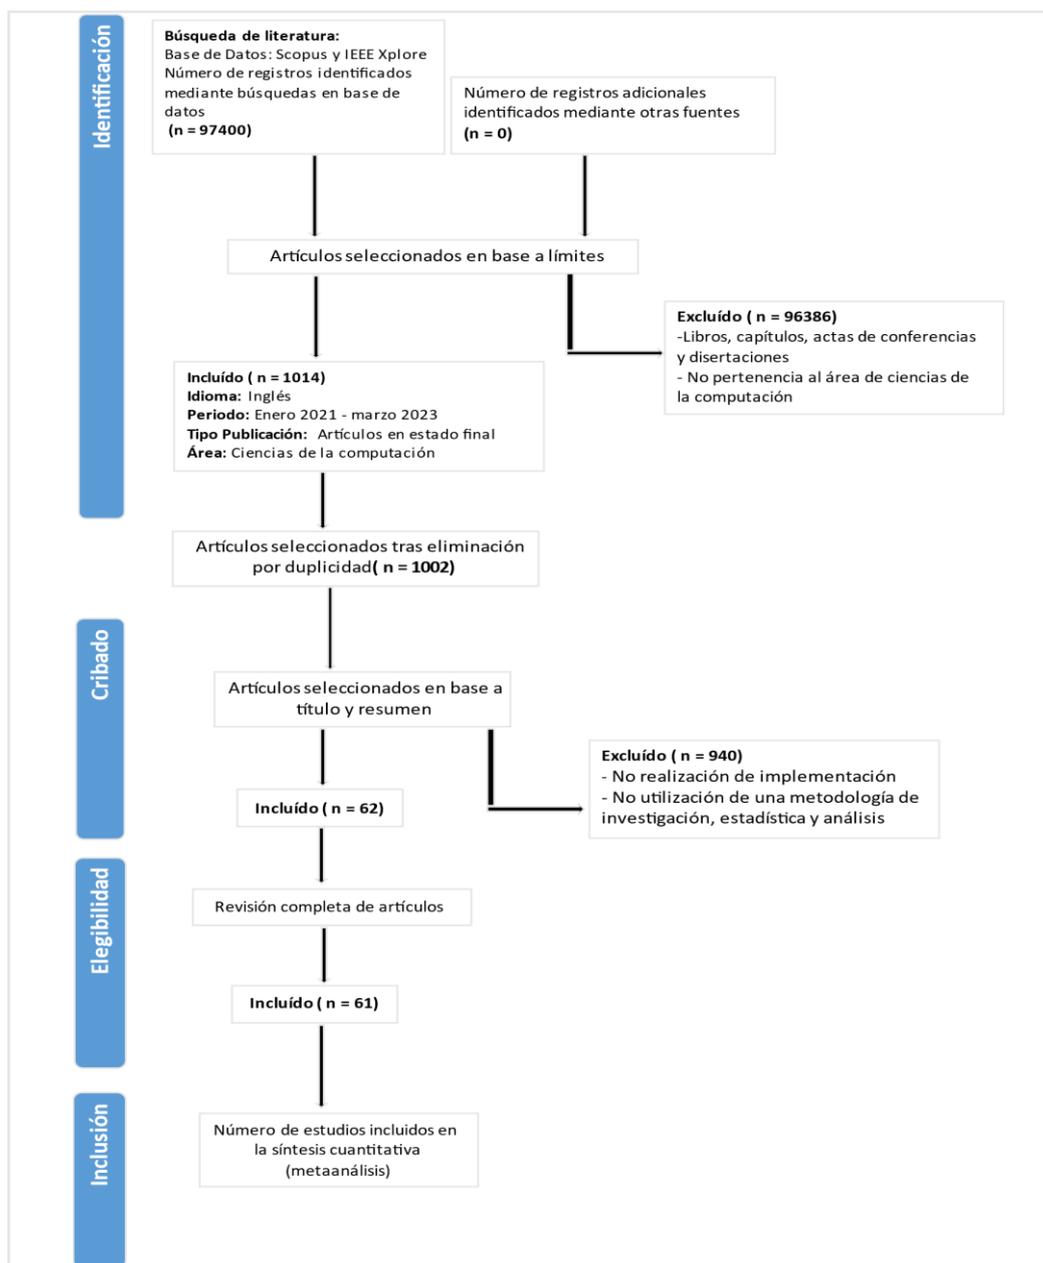


Figura 1. Flujograma de la selección de estudios (Liberati et al., 2009)

Finalmente se aplica un análisis de los estudios obtenidos con el fin de poder identificar solo aquellos que contemplen trabajos de implementación relacionado a enfermedades cutáneas, quedando 61 trabajos para el análisis respectivo. La Figura 1 presenta el detalle de la extracción de estudios, y el proceso se puede visualizar en el siguiente enlace <https://bit.ly/3pZDcGU>.

La Tabla 2 muestra el número de estudios seleccionados después de aplicar el flujograma de la declaración PRISMA (Figura 1).

Tabla 2.

Estudios objetivos de la RSL

Fuente	Estudios potenciales	Estudios seleccionados
Scopus	96600	51
IEEE Xplore	800	10
Total	97400*	61*

Nota: *Resultados finales de los estudios potenciales y seleccionados

Se identifican los artículos de mayor relevancia en el estudio mediante un conteo de frecuencias de citas que recibieron los artículos hasta la fecha de corte (Figura 2).

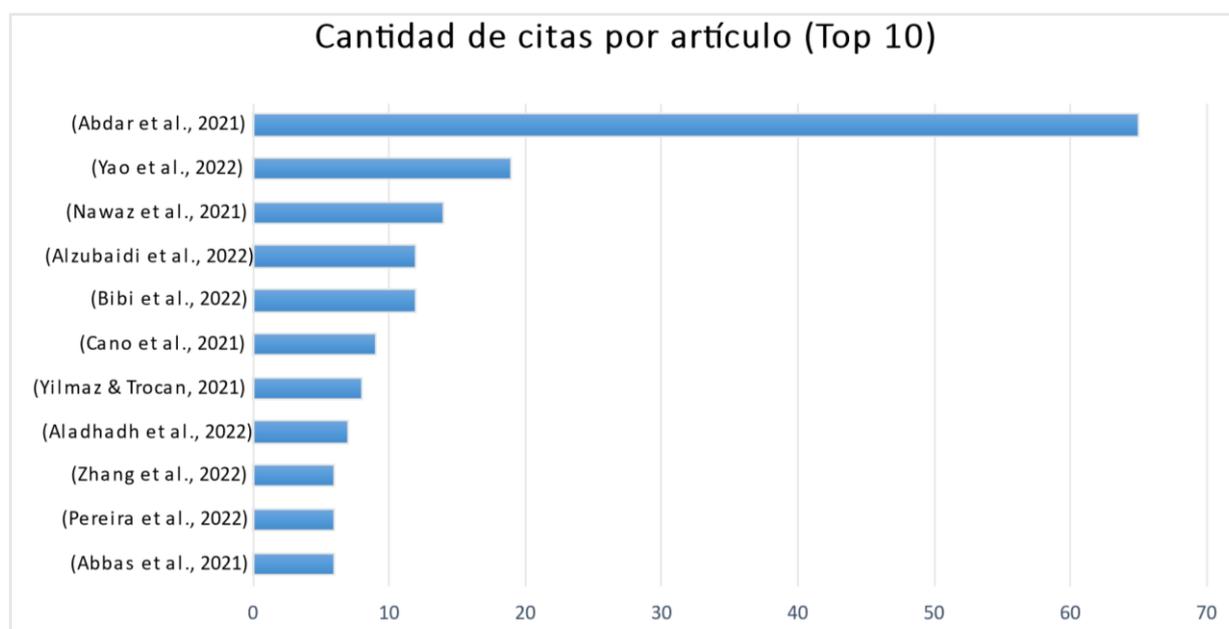


Figura 2. Cantidad de citas por artículo (Top 10)

En la Figura 2 se observa que la investigación de Abdar et al. (2021) ha obtenido la mayor cantidad de citas, mientras que Abbas et al. (2021) la menor cantidad. Esto implica que el trabajo de Abdar et al. (2021) ha generado un interés considerable en el campo de investigación, representando un 36,63% del total de citas, mientras que Abbas et al. (2021) es aquel que menor interés genera.

Se identifica las palabras claves de los estudios objetivos con el fin de alcanzar una mejor comprensión de la tendencia y enfoque de la investigación (Figura 3).

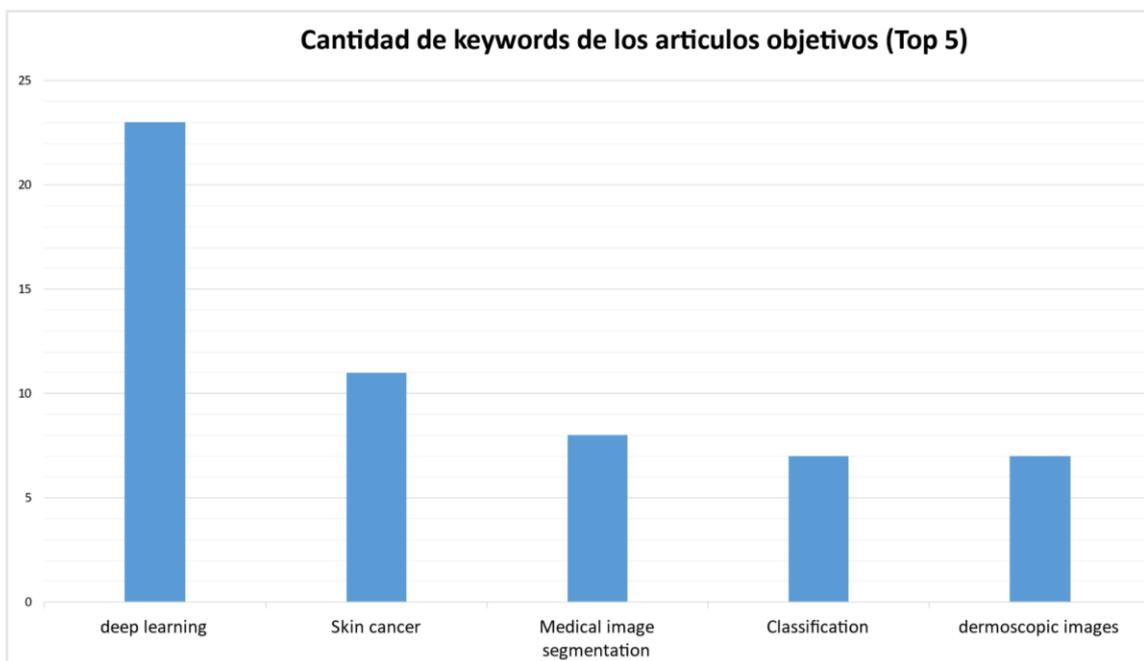


Figura 3. Cantidad de keywords de los artículos objetivos

En la Figura 3 se puede observar que la palabra clave con mayor frecuencia es "deep learning" (23 keywords). En ese sentido, se puede inferir que el deep learning tiene una alta relación con el tema de investigación.

Se realiza la identificación de la nacionalidad de los autores participantes en las diferentes publicaciones asociadas al tema de estudio. Esto con la finalidad de conocer la cantidad de investigadores en cada país (Figura. 4).

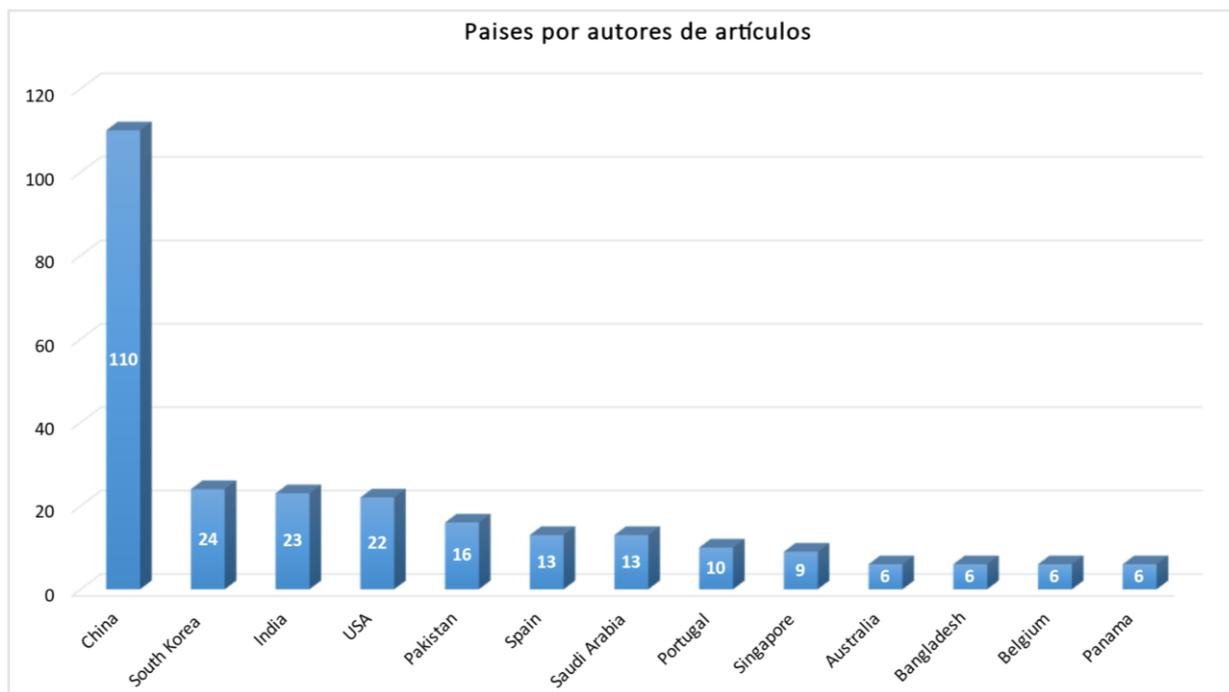


Figura 4. Países por autores de artículos

En la Figura 4 se observa que la mayor cantidad de investigadores provienen de China (110) seguidamente de Corea del Sur (24) y la India (23). Mientras que países como Venezuela, Iraq y Eslovenia son los que menor cantidad de investigadores tienen.

3.2. Análisis de resultados

Para obtener los resultados de investigación se realizó un análisis cuantitativo en las preguntas i y ii, a partir de librerías y lesiones dermatológicas. Asimismo, se aplicó un análisis cualitativo en la pregunta iii a través de un conteo de frecuencias, considerando los factores rendimiento y complejidad. El proceso de análisis se puede visualizar en el siguiente enlace: <https://bit.ly/3RtruiT>.

Pi. ¿Qué librerías son utilizadas en implementaciones de sistemas de análisis de imágenes dermatológicas?

La Tabla 3 presenta una recopilación de bibliotecas de software de los diversos estudios considerados en la investigación, las cuales son utilizadas para la construcción y entrenamiento de modelos de aprendizaje automático en la implementación de un sistema de análisis de imágenes dermatológicas.

Tabla 3.

Librerías para la implementación de sistemas de AID

Artículo	Librerías	Descripción
Abbas et al. (2021); Back et al. (2021); Cai et al. (2023); Cui et al. (2023); Gu et al. (2021); Han et al. (2023); He et al. (2023); Lai et al. (2022); Lan et al. (2022); Lei et al. (2023); Morgado et al. (2021); Nguyen et al. (2022); Qiu et al. (2023); Wang et al. (2023); Wu et al. (2021); Yao et al. (2022); Zhang et al. (2022); H. Zhao et al. (2022)	Pytorch	Para su implementación se utilizó la librería Pytorch de Python, ya que es una librería eficiente y popular de aprendizaje profundo que posibilitó el alcance de una variedad de tareas, incluida la segmentación de imágenes médicas y el entrenamiento de la red neuronal.
Cai et al. (2023); Gálvez et al. (2021); Wei zhu et al. (2022)	Numpy	Numpy permite almacenar y manipular grandes conjuntos de datos multidimensionales de manera eficiente, lo cual es importante en el análisis de imágenes, donde se trabaja con matrices de píxeles, asimismo, ofrece una amplia gama de funciones y operaciones matemáticas y estadísticas que son necesarias para el procesamiento de imágenes dermatológicas. Estas funciones incluyen cálculos de promedios, desviaciones estándar, operaciones de álgebra lineal, convolución, interpolación y transformaciones geométricas, entre otras.
Bala et al. (2023)	Scikit	Para la implementación del modelo MonkeyNet se utilizó la librería Scikit de Python, ya que permitió la construcción de la red neuronal, asimismo como su entrenamiento para la identificación eficiente de la viruela del mono.
Abbas et al. (2021); Aladhadh et al. (2022); Cano et al. (2021); La Salvia et al. (2022); Lou et al. (2023); Phan et al. (2023)	Keras	Para su implementación se utilizó la librería Keras, ya que es una librería potente para poder crear y entrenar redes neuronales, el cual permitió la realización de la adaptación del modelo U-net con el fin de poder generar un modelo eficiente de análisis de imágenes dermatológicas.
Aladhadh et al. (2022); Ashtari et al. (2023); Cano et al. (2021); La Salvia et al. (2022); Li et al. (2022); Phan et al. (2023)	Tensorflow	Para la implementación de los diferentes modelos se utilizó la librería de Tensorflow, ya que proporcionó una flexibilidad en el desarrollo y una eficiencia en la ejecución utilizando GPU y TPU, herramientas integradas de visualización y depuración, lo cual permitió el desarrollo y entrenamiento de modelos sofisticados para el diagnóstico clínico cutáneo.
Gálvez et al. (2021); Szolga et al. (2001); Wei zhu et al. (2022)	OpenCv	Los autores proponen la librería OpenCv de Python para poder lograr un análisis oportuno en la clasificación de lesiones en imágenes médicas. OpenCv se permitió manipular y analizar imágenes en tiempo real en términos de distintas perspectivas (3D/2D), proporcionando una amplia gama de funciones y

		algoritmos para el procesamiento de imágenes, detección de características, segmentación y reconocimiento de objetos en la piel.
Szolga et al. (2001)	Tkinter	Para la implementación del modelo se utilizó la librería Tkinter(GUI), la cual permite crear interfaces de usuarios intuitivas que apoye a los especialistas en la toma de decisiones de sus diagnósticos. Posee una amplia gama de componentes que permite poder construir interfaces de manera rápida, asimismo, debido a su adaptación con Python permite integrarse de manera eficiente y simple con diferentes librerías de aprendizaje profundo.

En la Tabla 4 se muestra las bibliotecas de software que mayor aplicación han presentado entre los diversos estudios para la construcción y entrenamiento de modelos de aprendizaje profundo en la implementación de un sistema de análisis de imágenes dermatológicas.

Tabla 4.

Librerías más utilizadas en implementaciones de sistemas de AID

Referencia	Librería	Descripción
Abbas et al. (2021); Ashtari et al. (2023); Back et al. (2021); Cai et al. (2023); Gu et al. (2021); Han et al. (2023); He et al. (2023); Karri et al. (2023); Lai et al. (2022); Lan et al. (2022); Lei et al. (2023); Morgado et al. (2021); Nguyen et al. (2022); Qiu et al. (2023); Wang et al. (2023); Wu et al. (2021); Yao et al. (2022); Zhang et al. (2022); H. Zhao et al. (2022)	Pytorch	En base a los estudios analizados, se observa que la librería Pytorch ofrece numerosas ventajas y funcionalidades para aplicaciones de análisis dermatológico. Específicamente, se destacan tres áreas principales de aplicación: clasificación de lesiones de la piel, segmentación de lesiones cutáneas y síntesis de imágenes. En lo que respecta a la clasificación de lesiones de la piel, Pytorch permitió entrenar modelos de aprendizaje profundo con el objetivo de lograr una clasificación precisa de diversos tipos de lesiones cutáneas, como el melanoma y el carcinoma de células basales. En cuanto a la segmentación de lesiones cutáneas, Pytorch se destacó por su capacidad para construir redes neuronales versátiles y robustas que pueden eliminar interferencias y ruidos, logrando así una segmentación eficiente de las áreas afectadas. En relación con la síntesis de imágenes, Pytorch resulta invaluable para la reconstrucción y generación de efectos realistas en las áreas de lesión debido a sus diversas funciones incorporadas.
Abbas et al. (2021); Aladhadh et al. (2022); Cano et al. (2021); La Salvia et al. (2022); Lou et al. (2023); Phan et al. (2023)	Keras	En base a los estudios analizados, se observa que la librería Keras ofrece una amplia gama de funcionalidades para el análisis de imágenes dermatológicas. Al utilizar Keras se obtuvieron resultados relevantes como la capacidad de implementar y entrenar redes neuronales convolucionales (CNN) específicamente diseñadas para lograr una clasificación precisa de imágenes de la piel, permitiendo así la detección automática de enfermedades dermatológicas. Asimismo, Keras proporcionó herramientas para realizar una segmentación precisa de lesiones, lo que facilitó la identificación y delimitación de áreas problemáticas en las imágenes médicas. Por último, la librería ofreció capacidades de visualización y simulación de las lesiones dermatológicas, lo que permitió comprender y mejorar el proceso de diagnóstico.
Aladhadh et al. (2022); Ashtari et al. (2023); Cano et al. (2021); La Salvia et al. (2022); Li et al. (2022); Phan et al. (2023)	Tensorflow	En base a los estudios analizados, se observa que la librería Tensorflow ofrece una amplia gama de funcionalidades que van desde la segmentación automática de enfermedades de la piel hasta la

		visualización y/o simulación de anomalías cutáneas. En lo que respecta a la segmentación, Tensorflow proporciona herramientas lo cual permite identificar y delimitar áreas específicas de interés. Esto facilita el análisis detallado de regiones particulares. Otro resultado significativo es la capacidad de detección de objetos en imágenes dermatológicas. Utilizando Tensorflow, se pudo identificar y localizar características específicas de lunares, manchas y lesiones, lo cual es especialmente valioso en el diagnóstico temprano, ya que ayuda a los médicos a poder generar diagnósticos más precisos y eficientes.
Cai et al. (2023); Gálvez et al. (2021); Wei zhu et al. (2022)	Numpy	En base a los estudios analizados, se observa que la librería Numpy facilitó la preparación y el preprocesamiento de los datos de entrada, así como el diseño y entrenamiento de las redes neuronales propuestos en los diversos estudios. Además, permitió realizar predicciones precisas en nuevas imágenes de enfermedades cutáneas, lo que ayudó en el diagnóstico y clasificación de las enfermedades de la piel de manera automatizada y eficiente.
Gálvez et al. (2021); Szolga et al. (2001); Wei zhu et al. (2022)	OpenCv	En base a los estudios analizados, se observa que la librería OpenCv permitió obtener resultados valiosos, como el mejoramiento de la calidad de las imágenes, la segmentación de áreas de interés, la detección de contornos y características, y la clasificación automatizada de enfermedades de la piel. Estas capacidades permitieron un análisis más preciso y eficiente de las imágenes dermatológicas, facilitando el diagnóstico de las enfermedades cutáneas.

Pii. ¿Qué lesiones dermatológicas pueden ser analizadas mediante reconocimiento por visión computacional?

La Tabla 5 presenta una recopilación de lesiones dermatológicas que pueden ser analizadas por visión computacional mediante la identificación de características sospechosas (color, forma y textura) en la piel.

Tabla 5.
Lesiones dermatológicas analizadas por visión computacional

Artículo	Lesiones dermatológicas	Descripción
Abdar et al. (2021); Aladhadh et al. (2022); Albraikan et al. (2023); Cano et al. (2021); Choudhary et al. (2021); Deng et al. (2021); Gálvez et al. (2021); Jaisakthi et al. (2022); Jiji et al. (2021); Karri et al. (2023); Kosgiker et al. (2021); Lan et al. (2022); Lei et al. (2023); Liu et al. (2023); Nawaz et al. (2021); Pereira et al. (2022); Phan et al. (2023); Qiu et al. (2023); Quero-Caiza & Altuve (2021); Thurnhofer-Hemsi et al. (2021); Wu et al. (2021); Yang & Lu (2022); Yilmaz & Trocan (2021); Zaid et al. (2022); Zhang et al. (2022); D. Zhao et al. (2023); H. Zhao et al. (2022)	Melanoma	El estudio pone énfasis en el trastorno más crítico de la piel, el melanoma, puesto que considera importante su identificación en etapas tempranas que tardías debido a su alto índice de mortalidad en el afectado. Por ende, el modelo presentado se enfoca en la detección oportuna de esta afección cutánea.
Aladhadh et al. (2022); Albraikan et al. (2023); Lan et al. (2022); Lei et al.	Nevus melanocítico	Los autores presentan modelos para poder identificar y clasificar con precisión dos tipologías del trastorno

(2023); Mansour et al. (2022); Pereira et al. (2022); Quero-Caiza & Altuve (2021); Yao et al. (2022); Zaid et al. (2022)	o (NV) / Nevus atípico	Nevus: Nevus común y Nevus Atípico. Estas enfermedades son de importancia crítica debido a sus implicaciones potenciales para la salud. Para lograr esto, los autores han extraído características discriminatorias clave que permiten una identificación precisa de estas condiciones. Estas características incluyen la forma, el tamaño, el color y el contorno de las lesiones cutáneas asociadas con cada una de estas enfermedades. Al utilizar estas características como criterios de clasificación, el modelo puede generar un diagnóstico más preciso para estas enfermedades cutáneas.
Aladhadh et al. (2022); Albraikan et al. (2023); Bibi et al. (2022); Karri et al. (2023); Kumar et al. (2022); Lan et al. (2022); Lei et al. (2023); Mansour et al. (2022); Yao et al. (2022); Zaid et al. (2022); H. Zhao et al. (2022)	Carcinoma de células basales (BCC),	Los autores identificaron el trastorno del carcinoma de celular basales (BCC), el cual es el tipo más común de cáncer de piel. Los estudios centran su atención en las características que incluyen la asimetría de forma, tamaño o distribución de colores de la lesión, bordes irregulares o mal definidos, presencia de diferentes tonalidades de color, vasos sanguíneos visibles, superficie brillante o perlada, así como úlceras o llagas que no cicatrizan. Estas características son importantes para la detección temprana y precisa del carcinoma de células basales, y el análisis automatizado de imágenes dermatológicas, utilizando algoritmos y técnicas de aprendizaje automático, puede contribuir en el diagnóstico y tratamiento oportunos de este tipo de cáncer de piel.
Aladhadh et al. (2022); Albraikan et al. (2023); Lan et al. (2022); Lei et al. (2023); Mansour et al. (2022); Thurnhofer-Hemsi et al. (2021); Yao et al. (2022); Zaid et al. (2022)	Queratosis actínica (AK)	Los autores presentan el trastorno de queratosis actínica (AK), el cual es también conocida como queratosis solar, esta se caracteriza por la presencia de parches escamosos, ásperos y con costras en áreas expuestas al sol, como la cara, las manos, los brazos y el cuero cabelludo. El sistema de análisis de imágenes dermatológicas debe prestar atención a ciertas características de la queratosis actínica que incluyen el tamaño, la forma y el color de las lesiones, así como su distribución en la piel. Además, el sistema debe considerar la presencia de áreas con textura áspera, descamación, costras y cambios de coloración.
Albraikan et al. (2023); Kosgiker et al. (2021); Liu et al. (2023); Mansour et al. (2022); Maqsood & Damaševičius, (2023)	Queratosis seborreica (SCC)	Los autores presentan el trastorno de Queratosis seborreica (SCC), el cual es una afección cutánea benigna muy común que se caracteriza por el desarrollo de lesiones elevadas, redondeadas y con apariencia verrugosa en la piel. Estas lesiones suelen ser de color marrón o negro, aunque también pueden ser de tonos más claros. A diferencia de otras afecciones cutáneas, la queratosis seborreica no está relacionada con la exposición al sol ni es precancerosa.
Kosgiker et al. (2021); Lei et al. (2023); Zaid et al. (2022)	Queratosis benigna	Los autores presentan la afección de Queratosis benigna que es una afección cutánea no cancerosa que se caracteriza por la presencia de lesiones planas, ásperas y escamosas en la piel. Estas lesiones suelen ser pequeñas y pueden variar en color, desde rosa claro hasta marrón. Aunque la queratosis benigna no representa un riesgo para la salud, puede ser estéticamente incómoda para algunas personas.
Aladhadh et al. (2022); Lan et al. (2022); Lei et al. (2023); Yao et al. (2022)	Dermatofibr oma (DF)	Los autores presentan el trastorno de Dermatofibroma la cual consiste en un nódulo o protuberancia en la piel. Esta se forma a partir de células fibroblásticas y puede variar en tamaño y color. Usualmente, se encuentra en las extremidades, especialmente en las piernas, pero también puede aparecer en otras áreas del cuerpo. Para

		su correcto análisis los sistemas de análisis deberán prestar atención en algunos aspectos relevantes a considerar que incluyen el tamaño, la forma, el color y la textura de la lesión.
Bibi et al. (2022); Kumar et al. (2022); Lei et al. (2023); Mansour et al. (2022); Zaid et al. (2022); H. Zhao et al. (2022)	Carcinoma de células escamosas	Los autores presentan el trastorno de Carcinoma de células escamosas, el cual consiste es un tipo de cáncer de piel que se origina en las células escamosas de la epidermis, la capa más externa de la piel. Este tipo de cáncer puede desarrollarse en áreas expuestas al sol, como la cara, el cuello, las orejas, los labios y las manos, pero también puede surgir en otras partes del cuerpo. En ese sentido los sistemas deben prestar atención a las características específicas de la lesión para su detección y evaluación precisa. Algunas de estas características incluyen la forma y el tamaño de las lesiones, la textura escamosa y áspera de la superficie, la presencia de costras y úlceras.
Albraikan et al. (2023); Lei et al. (2023); Zaid et al. (2022)	Lesión vascular (VASC)	Los autores presentan la afección de lesión vascular (VASC), el cual se refiere a una afección cutánea que implica la presencia de anomalías en los vasos sanguíneos de la piel. Estas lesiones pueden variar en apariencia y características, y se clasifican en diferentes tipos, como malformaciones vasculares, hemangiomas o telangiectasias. Para su identificación los sistemas deberán prestar atención en aspectos que incluyen la apariencia y la distribución de los vasos sanguíneos anómalos en la piel, así como el tamaño, la forma y el color de las lesiones.
Yao et al. (2022)	Enfermedad de Bowen	EL autor presenta el trastorno de la enfermedad de Bowen, el cual consiste en una forma de carcinoma de células escamosas in situ que afecta la capa más externa de la piel, conocida como la epidermis. Esta enfermedad se caracteriza por la presencia de lesiones escamosas, rojas y escamosas que pueden ser planas o elevadas. Para su identificación, los sistemas deberán prestar atención en variaciones que van desde manchas rojas y escamosas hasta placas gruesas y descamativas en la piel.
Bala et al. (2023)	Viruela del mono	El autor presenta un modelo para poder identificar con precisión la enfermedad cutánea de la viruela del mono, para ello se obtuvo las características principales del trastorno tales como tamaño, morfología, color y contraste de modo que permita la construcción exitosa y eficiente del modelo.
Bing et al. (2023)	Cancer de mama	El estudio pone énfasis en la detección de una de las enfermedades más comunes en mujeres, el cáncer de mama. El autor propone el siguiente método con el fin de poder extraer características comunes para la detección de este trastorno, tales como: morfología, color y contraste.
Phan et al. (2023)	Hiperpigmentación	El autor centra la investigación en el trastorno de la hiperpigmentación. De esta enfermedad se extrajo características que permitan poder realizar el análisis más eficiente, tales como: color, tamaño y la morfología de la lesión de modo que se pueda obtener un análisis más preciso.
Alzubaidi et al. (2022)	Carcinoma invasivo y Carcinoma in situ	El autor presenta el siguiente modelo para poder identificar y clasificar con precisión dos de las más críticas enfermedades de la piel: Carcinoma invasivo y el Carcinoma in situ. Para ello, el autor precisa que se extrajo características discriminatorias que permitan su

		identificación como son: la forma, el tamaño, el color y el contorno de las lesiones mencionadas.
Szolga et al. (2001)	Lunares benignos	El estudio se centró en la clasificación de lunares benignos. Para lo cual, se tuvo que extraer características comunes tales como: color y forma. De modo que el modelo entrene y genere un diagnóstico óptimo.
Abbas et al. (2021)	Melanoma Acral (MA)	El autor presenta la siguiente técnica para identificar y clasificar con precisión una de las enfermedades de la piel más críticas: el Melanoma Acral. Para lograrlo, se extrajeron características discriminatorias clave que permiten su identificación, como la forma, el tamaño, el color y el contorno de las lesiones mencionadas específicamente en este tipo de melanoma.
Phan et al. (2023)	Acné	El autor presenta el trastorno del acné, el cual ha demostrado una dificultad moderada debido a los múltiples factores que pueden ser analizados para su identificación tales como: protuberancia del área, el color y morfología de la lesión.
Jiji et al. (2021)	Psoriasis y Quistes Sebáceos	El autor presenta el siguiente modelo para poder identificar enfermedades de baja y alta criticidad. En lo que respecta a las de baja criticidad tenemos, al acné, puesto que para su identificación no requiere muchas características que el modelo deberá entrenar con el fin de detectarlo. En cambio, la psoriasis, melanoma y quistes sebáceos son trastornos que requieren una mayor cantidad de parámetros para su detección tales como: color, morfología y tamaño.
Back et al. (2021)	Herpes zóster (HZ)	El autor presenta el siguiente modelo para identificar y clasificar con precisión el Herpes Zoster, una enfermedad crítica de la piel. Para su identificación se han extraído características discriminatorias, como la forma, el tamaño, el color y el contorno de las lesiones, para facilitar su identificación.

Piii. ¿Cuáles son las lesiones de la piel más complejas de analizar mediante reconocimiento por visión computacional?

En la Tabla 6 se identifican las lesiones dermatológicas que mayor complejidad han presentado por visión computacional, las cuales contemplan factores como la identificación de características (color, forma y textura) de la piel.

Tabla 6.

Lesiones con mayor complejidad por visión computacional

Referencia	Lesión	Observación
Abdar et al. (2021); Aladhadh et al. (2022); Albraikan et al. (2023); Cano et al. (2021); Choudhary et al. (2021); Deng et al. (2021); Gálvez et al. (2021); Jaisakthi et al. (2022); Jiji et al. (2021); Karri et al. (2023); Kosgiker et al. (2021); Lan et al. (2022); Lei et al. (2023); Liu et al. (2023); Nawaz et al. (2021); Pereira et al. (2022); Phan et al. (2023); Qiu et al. (2023); Quero-Caiza & Altuve (2021); Thurnhofer-Hemsi et al. (2021); Wu et al. (2021); Yang & Lu (2022); Yilmaz & Trocan (2021); Zaid et al. (2022); Zhang et al.	Melanoma (MEL)	Se considera que el melanoma presenta un desafío significativo debido a su complejidad y gravedad, ya que para su identificación se requiere una gran variedad de características visuales y técnicas avanzadas de procesamiento de imágenes, aprendizaje automático y análisis clínico para lograr una precisión y confiabilidad adecuada en la detección y clasificación de melanoma. Asimismo, es fundamental contar con un conjunto de datos bien anotado y diverso, así como una validación rigurosa del modelo para garantizar resultados eficientes.

(2022); D. Zhao et al. (2023); H. Zhao et al. (2022)		
Aladhadh et al. (2022); Albraikan et al. (2023); Bibi et al. (2022); Karri et al. (2023); Kumar et al. (2022); Lan et al. (2022); Lei et al. (2023); Mansour et al. (2022); Yao et al. (2022); Zaid et al. (2022); H. Zhao et al. (2022)	Carcinoma de células basales (BCC)	Se considera que el Carcinoma de células basales (BCC) implica una complejidad considerable debido a la necesidad de identificar características sutiles y diferenciar lesiones cancerosas de benignas. Asimismo, se requiere un enfoque multidisciplinario y un conjunto de datos representativos para desarrollar un modelo preciso y confiable.
Aladhadh et al. (2022); Albraikan et al. (2023); Lan et al. (2022); Lei et al. (2023); Mansour et al. (2022); Thurnhofer-Hemsi et al. (2021); Yao et al. (2022); Zaid et al. (2022)	Queratosis Actínica (AK)	Se considera que la Queratosis Actínica (AK) presenta una complejidad considerable debido a la necesidad de identificar características específicas y diferenciar las lesiones precancerosas de otras afecciones de la piel. Asimismo, se requiere el uso de técnicas avanzadas de procesamiento de imágenes y algoritmos de aprendizaje automático, así como una validación rigurosa para garantizar resultados precisos y confiables en el diagnóstico de esta enfermedad cutánea.
Aladhadh et al. (2022); Albraikan et al. (2023); Lan et al. (2022); Lei et al. (2023); Thurnhofer-Hemsi et al. (2021); Yao et al. (2022); Zaid et al. (2022)	Lesión vascular (VASC)	Se considera que la lesión vascular (VASC) presenta una complejidad considerable debido a la necesidad de identificar características relacionadas con los vasos sanguíneos y la variabilidad en la apariencia de las lesiones. Asimismo, se requiere técnicas avanzadas de procesamiento de imágenes, un conjunto de datos representativo y una validación rigurosa para lograr resultados precisos en el diagnóstico de estas afecciones cutáneas vasculares.
Bibi et al. (2022); Kumar et al. (2022); Lei et al. (2023); Mansour et al. (2022); Zaid et al. (2022); H. Zhao et al. (2022)	Carcinoma de células escamosas (SCC)	Se considera que la lesión de Carcinoma de células escamosas (SCC) en imágenes dermatológicas conlleva una complejidad significativa debido a la necesidad de identificar características específicas y distinguir las lesiones malignas de otras afecciones cutáneas. Requiere un enfoque multidisciplinario, conocimientos especializados y técnicas avanzadas de procesamiento de imágenes y aprendizaje automático.
Bing et al. (2023)	Cancer de mama	Se considera que la enfermedad de Cáncer de mama presenta una complejidad alta debido a la variabilidad y la heterogeneidad de la enfermedad. Debido a estos factores se requieren técnicas avanzadas de procesamiento de imágenes para la detección y clasificación.
Albraikan et al. (2023); Kosgiker et al. (2021); Liu et al. (2023); Mansour et al. (2022); Maqsood & Damaševičius, (2023)	Queratosis seborreica	Se considera que la enfermedad de la Queratosis seborreica implica una complejidad alta debido a las características variables y la similitud visual con otras lesiones cutáneas. Por ello, requiere técnicas avanzadas de procesamiento de imágenes para detectar y clasificarlas con precisión.
Yao et al. (2022)	Enfermedad de Bowen (AK)	Se considera que la lesión de Bowen implica una complejidad alta debido a la diversidad en la apariencia y la necesidad de distinguir entre lesiones benignas y potencialmente malignas. Requiere técnicas avanzadas de procesamiento de imágenes y aprendizaje automático para detectar y clasificar las lesiones de manera precisa.
Alzubaidi et al. (2022)	Carcinoma invasivo	Se considera que las lesiones de Carcinoma invasivo conlleva una complejidad considerable debido a la naturaleza agresiva y heterogénea de la enfermedad. Para lo cual requiere técnicas avanzadas de procesamiento de imágenes y aprendizaje automático

		para la detección, caracterización y clasificación precisas de las lesiones.
Abbas et al. (2021)	Melanoma Acral (MA)	Se considera que las lesiones del Melanoma Acral (MA) presentan una complejidad alta debido a las características únicas de esta forma de melanoma. Por lo que requiere técnicas de procesamiento de imágenes y aprendizaje automático para la detección y caracterización precisas de las lesiones.
Jiji et al. (2021)	Psoriasis	Se considera que las lesiones de la Psoriasis presentan cierta complejidad debido a la naturaleza crónica y variable de las lesiones. Debido a ello, requiere técnicas de procesamiento de imágenes para la detección y clasificación precisa de las lesiones.
Quero-Caiza & Altuve (2021)	Nevus atípico	Se considera que las lesiones de Nevus atípico tienen una complejidad alta debido a su naturaleza variable y potencialmente preocupante. Estos lunares presentan características inusuales y pueden tener un mayor riesgo de convertirse en melanoma. Por lo que, es necesario contar con un conjunto de datos anotados que incluya casos de nevus atípicos y melanoma, y validar el modelo utilizando datos independientes y la opinión de dermatólogos expertos.
Back et al. (2021)	Herpes zóster (HZ)	Se considera que las lesiones de Herpes Zoster (HZ) presentan una complejidad alta debido a las características variables de esta enfermedad. Por lo que requiere técnicas de procesamiento de imágenes para detectar y caracterizar las lesiones cutáneas, así como la identificación de patrones y la evaluación de la gravedad.

CONCLUSIONES

Se identifican 7 librerías de software para el AID, lo cual evidencia que existen tecnologías disponibles en este campo. No obstante, a pesar de que estas tecnologías están documentadas, no hay muchas iniciativas para desarrollar estándares en este rubro, a nivel general se tienen librerías gráficas que son utilizadas en análisis de datos, reconocimientos de patrones, reconocimiento facial, reconocimiento de objetos, etc., pero pocas trabajan directamente sobre el análisis dermatológico, esto puede deberse a la estructura no homogénea de las lesiones en la piel y los distintos tonos existentes, lo cual representa un reto significativo para crear el modelo computacional correcto. Con respecto a las lesiones, se identificaron 13, permitiendo inferir que existe una variedad de trastornos en la piel que requieren atención. La detección temprana de estas lesiones adquiere importancia significativa con el fin de mitigar las consecuencias y síntomas de su implicación.

Respecto a las librerías utilizadas se identifica que la de mayor rendimiento es Pytorch, ya que demostró un alto aporte en la construcción y entrenamiento de modelos de inteligencia artificial. Sin embargo, posee una curva de aprendizaje muy alta, por lo que exige tener conocimientos previos de estructura de datos y gráficos dinámicos para su aplicación. Con relación a las lesiones, se observó que el Melanoma es el que mayor complejidad genera al ser evaluadas por visión computacional. A pesar de que la integración de técnicas de análisis computacional apoya en su identificación, el juicio clínico sigue siendo crucial, debido a la diversidad de factores que pueden presentar las lesiones de la piel en diferentes contextos.

La revisión revela que existen herramientas informáticas robustas para las implementaciones de sistemas AID que permiten la identificación y clasificación de trastornos de la piel mediante el análisis de imágenes dermatológicas, sin embargo, existen otras aplicaciones que se podrían implementar con relación al análisis dermatológico. Una recomendación para futuras investigaciones sería la de integrar herramientas

IoT en el proceso de análisis de modo que posibilite la transmisión de información entre dispositivos remotos dando lugar a la Telemedicina. Otra línea de investigación podría centrarse en la exploración de diversas herramientas Cloud que permita realizar análisis más escalables debido a la gran cantidad de centros de salud que brindan servicios de atención a diversos pacientes.

FINANCIAMIENTO

El autor no recibió patrocinio para llevar a cabo este estudio-artículo.

CONFLICTO DE INTERESES

No existe ningún tipo de conflicto de interés relacionado con la materia del trabajo.

CONTRIBUCIÓN DE LOS AUTORES

Conceptualización, curación de datos, análisis formal, adquisición de fondos, investigación, administración del proyecto, software, supervisión, validación, visualización, redacción -borrador original y redacción -revisión y edición: Huanatico-Lipa, J. C. y Coral-Ygnacio, M.

REFERENCIAS BIBLIOGRÁFICAS

- Abbas, Q., Ramzan, F., & Ghani, M. U. (2021). Acral melanoma detection using dermoscopic images and convolutional neural networks. *Visual Computing for Industry, Biomedicine, and Art*, 4(1). <https://doi.org/10.1186/s42492-021-00091-z>
- Abdar, M., Samami, M., Dehghani Mahmoodabad, S., Doan, T., Mazouze, B., Hashemifesharaki, R., Liu, L., Khosravi, A., Acharya, U. R., Makarenkov, V., & Nahavandi, S. (2021). Uncertainty quantification in skin cancer classification using three-way decision-based Bayesian deep learning. *Computers in Biology and Medicine*, 135(April), 104418. <https://doi.org/10.1016/j.combiomed.2021.104418>
- Aladhadh, S., Alsanea, M., Aloraini, M., Khan, T., Habib, S., & Islam, M. (2022). An Effective Skin Cancer Classification Mechanism via Medical Vision Transformer. *Sensors*, 22(11). <https://doi.org/10.3390/s22114008>
- Albraikan, A. A., Nemri, N., Alkhonaini, M. A., Hilal, A. M., Yaseen, I., & Motwakel, A. (2023). Automated Deep Learning Based Melanoma Detection and Classification Using Biomedical Dermoscopic Images. *Computers, Materials and Continua*, 74(2), 2443–2459. <https://doi.org/10.32604/cmc.2023.026379>
- Alcantud Marín, F., Alonso Esteban, Y., & Rico Bañón, D. (2015). Herramientas de cribado para la detección de retrasos o trastornos en el desarrollo: Una revisión sistemática de la literatura. *Revista Española De Discapacidad*, 3(2), 7–26. <https://www.cedid.es/redis/index.php/redis/article/view/189>
- Alzubaidi, L., Fadhel, M. A., Al-Shamma, O., Zhang, J., Santamaría, J., & Duan, Y. (2022). Robust application of new deep learning tools: an experimental study in medical imaging. *Multimedia Tools and Applications*, 81(10), 13289–13317. <https://doi.org/10.1007/s11042-021-10942-9>
- Ashtari, P., Sima, D. M., De Lathauwer, L., Sappey-Marinier, D., Maes, F., & Van Huffel, S. (2023). Factorizer: A scalable interpretable approach to context modeling for medical image segmentation. *Medical Image Analysis*, 84(February 2022), 102706. <https://doi.org/10.1016/j.media.2022.102706>
- Back, S., Lee, S., Shin, S., Yu, Y., Yuk, T., Jong, S., Ryu, S., & Lee, K. (2021). Robust Skin Disease Classification by Distilling Deep Neural Network Ensemble for the Mobile Diagnosis of Herpes Zoster. *IEEE Access*, 9, 20156–20169. <https://doi.org/10.1109/ACCESS.2021.3054403>
- Bala, D., Hossain, M. S., Hossain, M. A., Abdullah, M. I., Rahman, M. M., Manavalan, B., Gu, N., Islam, M. S., &

- Huang, Z. (2023). MonkeyNet: A robust deep convolutional neural network for monkeypox disease detection and classification. *Neural Networks*, 161, 757–775. <https://doi.org/10.1016/j.neunet.2023.02.022>
- Bibi, A., Khan, M. A., Javed, M. Y., Tariq, U., Kang, B. G., Nam, Y., Mostafa, R. R., & Sakr, R. H. (2022). Skin lesion segmentation and classification using conventional and deep learning based framework. *Computers, Materials and Continua*, 71(2), 2477–2495. <https://doi.org/10.32604/cmc.2022.018917>
- Bing, S., Chawang, K., & Chiao, J.-C. (2023). A Tuned Microwave Resonant System for Subcutaneous Imaging. *Sensors*, 23(6), 3090. <https://doi.org/10.3390/s23063090>
- Caballé, N., Castillo, J. L., Gómez, J. A., Gómez, J. M., & Polo, M. (2020). Machine Learning Applied to Diagnosis of Human Diseases : A Systematic Review. *Applied Sciences*, 1–27. <https://doi.org/10.3390/app10155135>
- Cai, Y., Chen, H., Yang, X., Zhou, Y., & Cheng, K.-T. (2023). Dual-distribution discrepancy with self-supervised refinement for anomaly detection in medical images. *Medical Image Analysis*, 86, 102794. <https://doi.org/10.1016/j.media.2023.102794>
- Cañedo, R., Rodriguez, R., & Marilis, M. (2010). Scopus : The largest database of peer-reviewed scientific literature available to underdeveloped countries Scopus : la mayor base de datos de literatura científica arbitrada al alcance de los países subdesarrollados Scopus : The largest database of peer-r. *ACIMED, February 2016*.
- Cano, E., Mendoza-Avilés, J., Areiza, M., Guerra, N., Mendoza-Valdés, J. L., & Rovetto, C. A. (2021). Multi Skin Lesions Classification using Fine-tuning and Data-augmentation Applying Nasnet. *PeerJ Computer Science*, 7(Mcc), 1–20. <https://doi.org/10.7717/PEERJ-CS.371>
- Choudhary, P., Singhai, J., & Yadav, J. S. (2021). Curvelet and fast marching method-based technique for efficient artifact detection and removal in dermoscopic images. *International Journal of Imaging Systems and Technology*, 31(4), 2334–2345. <https://doi.org/10.1002/ima.22633>
- Cui, R., Yang, R., Liu, F., & Geng, H. (2023). HD2A-Net: A novel dual gated attention network using comprehensive hybrid dilated convolutions for medical image segmentation. *Computers in Biology and Medicine*, 152(November 2022), 106384. <https://doi.org/10.1016/j.combiomed.2022.106384>
- Decharatanachart, P., Chaiteerakij, R., Tiyarattanachai, T., & Treeprasertsuk, S. (2021). Application of artificial intelligence in chronic liver diseases : a systematic review and meta - analysis. *BMC Gastroenterology*, 1–16. <https://doi.org/10.1186/s12876-020-01585-5>
- Deng, Q., Beltran, J. C. C., & Lee, D. H. (2021). Assessment of Segmentation Impact on Melanoma Classification Using Convolutional Neural Networks. *Journal of Computing Science and Engineering*, 15(3), 115–124. <https://doi.org/10.5626/JCSE.2021.15.3.115>
- Gálvez, A., Iglesias, A., Fister, I., Otero, C., & Díaz, J. A. (2021). NURBS functional network approach for automatic image segmentation of macroscopic medical images in melanoma detection. *Journal of Computational Science*, 56(April). <https://doi.org/10.1016/j.jocs.2021.101481>
- Gu, R., Wang, G., Song, T., Huang, R., Aertsen, M., Deprest, J., Ourselin, S., Vercauteren, T., & Zhang, S. (2021). CA-Net: Comprehensive Attention Convolutional Neural Networks for Explainable Medical Image Segmentation. *IEEE Transactions on Medical Imaging*, 40(2), 699–711. <https://doi.org/10.1109/TMI.2020.3035253>
- Han, Z., Huang, H., Lu, D., Fan, Q., Ma, C., Chen, X., Gu, Q., & Chen, Q. (2023). One-stage and lightweight CNN detection approach with attention: Application to WBC detection of microscopic images. *Computers in Biology and Medicine*, 154(October 2022), 106606.

<https://doi.org/10.1016/j.compbiomed.2023.106606>

- He, S., Feng, Y., Grant, P. E., & Ou, Y. (2023). Segmentation ability map: Interpret deep features for medical image segmentation. *Medical Image Analysis*, 84(December 2022), 102726. <https://doi.org/10.1016/j.media.2022.102726>
- Islam, M. M., Yang, H. C., Poly, T. N., Jian, W. S., & (Jack) Li, Y. C. (2020). Deep learning algorithms for detection of diabetic retinopathy in retinal fundus photographs: A systematic review and meta-analysis. *Computer Methods and Programs in Biomedicine*, 191, 1–16. <https://doi.org/10.1016/j.cmpb.2020.105320>
- Jaisakthi, S. M., Mirunalini, P., Aravindan, C., & Appavu, R. (2022). Classification of skin cancer from dermoscopic images using deep neural network architectures. *Multimedia Tools and Applications*, 15763–15778. <https://doi.org/10.1007/s11042-022-13847-3>
- Jiji, G. W., Rajesh, A., & Raj, P. J. D. (2021). CBI + R: A Fusion Approach to Assist Dermatological Diagnoses. *International Journal of Image and Graphics*, 21(1). <https://doi.org/10.1142/S0219467821500054>
- Karri, M., Annavarapu, C. S. R., & Acharya, U. R. (2023). Skin lesion segmentation using two-phase cross-domain transfer learning framework. *Computer Methods and Programs in Biomedicine*, 231. <https://doi.org/10.1016/j.cmpb.2023.107408>
- Kosgiker, G. M., Deshpande, A., & Kauser, A. (2021). SegCaps: An efficient SegCaps network-based skin lesion segmentation in dermoscopic images. *International Journal of Imaging Systems and Technology*, 31(2), 874–894. <https://doi.org/10.1002/ima.22545>
- Kumar, K. S., Suganthi, N., Muppidi, S., & Kumar, B. S. (2022). FSPBO-DQN: SeGAN based segmentation and Fractional Student Psychology Optimization enabled Deep Q Network for skin cancer detection in IoT applications. *Artificial Intelligence in Medicine*, 129(October 2021), 102299. <https://doi.org/10.1016/j.artmed.2022.102299>
- La Salvia, M., Torti, E., Leon, R., Fabelo, H., Ortega, S., Martinez-Vega, B., Callico, G. M., & Leporati, F. (2022). Deep Convolutional Generative Adversarial Networks to Enhance Artificial Intelligence in Healthcare: A Skin Cancer Application. *Sensors*, 22(16). <https://doi.org/10.3390/s22166145>
- Lai, H., Fu, S., Zhang, J., Cao, J., Feng, Q., Lu, L., & Huang, M. (2022). Prior Knowledge-Aware Fusion Network for Prediction of Macrovascular Invasion in Hepatocellular Carcinoma. *IEEE Transactions on Medical Imaging*, 41(10), 2644–2657. <https://doi.org/10.1109/TMI.2022.3167788>
- Lan, Z., Cai, S., He, X., & Wen, X. (2022). FixCaps: An Improved Capsules Network for Diagnosis of Skin Cancer. *IEEE Access*, 10(May), 76261–76267. <https://doi.org/10.1109/ACCESS.2022.3181225>
- Lei, J., Yang, G., Wang, S., Feng, Z., & Liang, R. (2023). Category-aware feature attribution for Self-Optimizing medical image classification. *Displays*, 77(February), 102397. <https://doi.org/10.1016/j.displa.2023.102397>
- Li, S., Xie, Y., Wang, G., Zhang, L., & Zhou, W. (2022). Attention guided discriminative feature learning and adaptive fusion for grading hepatocellular carcinoma with Contrast-enhanced MR. *Computerized Medical Imaging and Graphics*, 97(February), 102050. <https://doi.org/10.1016/j.compmedimag.2022.102050>
- Liberati, A., Altman, D. G., Tetzlaff, J., Mulrow, C., Gøtzsche, P. C., Ioannidis, J. P. A., Clarke, M., Devereaux, P. J., Kleijnen, J., & Moher, D. (2009). The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate health care interventions: explanation and elaboration. In *Journal of clinical epidemiology* (Vol. 62, Issue 10). <https://doi.org/10.1016/j.jclinepi.2009.06.006>
- Liu, Z., Xiong, R., & Jiang, T. (2023). CI-Net: Clinical-Inspired Network for Automated Skin Lesion

- Recognition. *IEEE Transactions on Medical Imaging*, 42(3), 619–632.
<https://doi.org/10.1109/TMI.2022.3215547>
- Lou, A., Guan, S., & Loew, M. (2023). CFPNet-M: A light-weight encoder-decoder based network for multimodal biomedical image real-time segmentation. *Computers in Biology and Medicine*, 154(December 2022), 106579. <https://doi.org/10.1016/j.compbimed.2023.106579>
- Mansour, R. F., Althubiti, S. A., & Alenezi, F. (2022). Computer Vision with Machine Learning Enabled Skin Lesion Classification Model. *Computers, Materials and Continua*, 73(1), 849–864.
<https://doi.org/10.32604/cmc.2022.029265>
- Maqsood, S., & Damaševičius, R. (2023). Multiclass skin lesion localization and classification using deep learning based features fusion and selection framework for smart healthcare. *Neural Networks*, 160, 238–258. <https://doi.org/10.1016/j.neunet.2023.01.022>
- Morgado, A. C., Andrade, C., Teixeira, L. F., & Vasconcelos, M. J. M. (2021). Incremental learning for dermatological imaging modality classification. *Journal of Imaging*, 7(9).
<https://doi.org/10.3390/jimaging7090180>
- Nawaz, M., Masood, M., Javed, A., Iqbal, J., Nazir, T., Mehmood, A., & Ashraf, R. (2021). Melanoma localization and classification through faster region-based convolutional neural network and SVM. *Multimedia Tools and Applications*, 80(19), 28953–28974. <https://doi.org/10.1007/s11042-021-11120-7>
- Nguyen, D. M. H., Nguyen, T. T., Vu, H., Pham, Q., Nguyen, M. D., Nguyen, B. T., & Sonntag, D. (2022). TATL: Task agnostic transfer learning for skin attributes detection. *Medical Image Analysis*, 78, 102359.
<https://doi.org/10.1016/j.media.2022.102359>
- Palacios, D., & Díaz, A. (2017). Dermatoscopia para principiantes (i): características generales. *Medicina de Familia SEMERGEN*, 43(3), 216–221. <https://doi.org/10.1016/j.semerg.2015.11.009>
- Pereira, P. M. M., Thomaz, L. A., Tavora, L. M. N., Assuncao, P. A. A., Fonseca-Pinto, R. M., Paiva, R. P., & Faria, S. M. M. d. (2022). Melanoma classification using light-Fields with morlet scattering transform and CNN: Surface depth as a valuable tool to increase detection rate. *Medical Image Analysis*, 75, 102254. <https://doi.org/10.1016/j.media.2021.102254>
- Phan, D. T., Ta, Q. B., Ly, C. D., Nguyen, C. H., Park, S., Choi, J., Se, H. O., & Oh, J. (2023). Smart Low Level Laser Therapy System for Automatic Facial Dermatological Disorder Diagnosis. *IEEE Journal of Biomedical and Health Informatics*, 27(3), 1546–1557. <https://doi.org/10.1109/jbhi.2023.3237875>
- Qiu, S., Li, C., Feng, Y., Zuo, S., Liang, H., & Xu, A. (2023). GFANet: Gated Fusion Attention Network for skin lesion segmentation. *Computers in Biology and Medicine*, 155(December 2022).
<https://doi.org/10.1016/j.compbimed.2022.106462>
- Quero-Caiza, W., & Altuve, M. (2021). Recognition of Skin Lesions in Dermoscopic Images using Local Binary Patterns and Multinomial Logistic Regression. *IEEE Latin America Transactions*, 20(7), 2020–2028. <https://doi.org/10.1109/TLA.2021.9827475>
- Szolga, L., Bozga, D., & Florea, C. (2001). End-User Skin Analysis (Moles) through Image Acquisition and Processing System. *Sensors*, 20, 9–11.
- Thurnhofer-Hemsi, K., Lopez-Rubio, E., Dominguez, E., & Elizondo, D. A. (2021). Skin lesion classification by ensembles of deep convolutional networks and regularly spaced shifting. *IEEE Access*, 9, 112193–112205. <https://doi.org/10.1109/ACCESS.2021.3103410>
- Wang, K., Zhang, X., Lu, Y., Zhang, W., Huang, S., & Yang, D. (2023). GSAL: Geometric structure adversarial learning for robust medical image segmentation. *Pattern Recognition*, 140, 109596.

<https://doi.org/10.1016/j.patcog.2023.109596>

- Wei zhu, Liu, L., Kuang, F., Li, L., Xu, S., & Liang, Y. (2022). An efficient multi-threshold image segmentation for skin cancer using boosting whale optimizer. *Computers in Biology and Medicine*, 151(PA), 106227. <https://doi.org/10.1016/j.compbio.2022.106227>
- Wu, H., Pan, J., Li, Z., Wen, Z., & Qin, J. (2021). Automated Skin Lesion Segmentation Via an Adaptive Dual Attention Module. *IEEE Transactions on Medical Imaging*, 40(1), 357–370. <https://doi.org/10.1109/TMI.2020.3027341>
- Wu, Yang, H., Peng, L., Lian, Z., Li, M., Qu, G., Jiang, S., & Han, Y. (2022). AGNet: Automatic generation network for skin imaging reports. *Computers in Biology and Medicine*, 141(June 2021), 105037. <https://doi.org/10.1016/j.compbio.2021.105037>
- Yang, C., & Lu, G. M. (2022). Skin Lesion Segmentation with Codec Structure Based Upper and Lower Layer Feature Fusion Mechanism. *KSII Transactions on Internet and Information Systems*, 16(1), 60–79. <https://doi.org/10.3837/tiis.2022.01.004>
- Yao, P., Shen, S., Xu, M., Liu, P., Zhang, F., Xing, J., Shao, P., Kaffenberger, B., & Xu, R. X. (2022). Single Model Deep Learning on Imbalanced Small Datasets for Skin Lesion Classification. *IEEE Transactions on Medical Imaging*, 41(5), 1242–1254. <https://doi.org/10.1109/TMI.2021.3136682>
- Yilmaz, E., & Trocan, M. (2021). A modified version of GoogLeNet for melanoma diagnosis. *Journal of Information and Telecommunication*, 5(3), 395–405. <https://doi.org/10.1080/24751839.2021.1893495>
- Zaid, M., Ali, S., Ali, M., Hussein, S., Saadia, A., & Sultani, W. (2022). Identifying out of distribution samples for skin cancer and malaria images. *Biomedical Signal Processing and Control*, 78(May), 103882. <https://doi.org/10.1016/j.bspc.2022.103882>
- Zhang, J., Liu, Y., Wu, Q., Wang, Y., Liu, Y., Xu, X., & Song, B. (2022). SWTRU: Star-shaped Window Transformer Reinforced U-Net for medical image segmentation. *Computers in Biology and Medicine*, 150(August), 105954. <https://doi.org/10.1016/j.compbio.2022.105954>
- Zhao, D., Qi, A., Yu, F., Heidari, A. A., Chen, H., & Li, Y. (2023). Multi-strategy ant colony optimization for multi-level image segmentation: Case study of melanoma. *Biomedical Signal Processing and Control*, 83(February), 104647. <https://doi.org/10.1016/j.bspc.2023.104647>
- Zhao, H., Wang, A., & Zhang, C. (2022). Research on melanoma image segmentation by incorporating medical prior knowledge. *PeerJ Computer Science*, 8. <https://doi.org/10.7717/PEERJ-CS.1122>