

<https://doi.org/10.24245/dermatolrevmex.v70i4.11326>

Uso de inteligencia artificial para la diferenciación entre melanoma y nevo melanocítico atípico

Use of artificial intelligence for the differentiation between melanoma and atypical melanocytic nevus.

Carolina Posada Ramírez,¹ Valeria Guerra Espinosa,⁴ Ángela Londoño García,² Camilo Arias Rodríguez,⁵ Oscar Iván Quirós Gómez³

Resumen

ANTECEDENTES: El melanoma tiene la mayor tasa de mortalidad entre los cánceres de piel, con un incremento anual del 3-5%. Su diferenciación frente a los nevos atípicos es un reto clínico complejo en el que la inteligencia artificial (IA) puede reducir errores y biopsias innecesarias.

OBJETIVO: Mapear y caracterizar la bibliografía científica acerca del uso de IA en la diferenciación entre melanoma y nevos melanocíticos atípicos.

METODOLOGÍA: Revisión de alcance (*scoping review*) siguiendo la guía PRISMA-ScR. Se buscaron artículos originales publicados entre 2015 y 2025 en PubMed, ScienceDirect y Medline. La selección de los estudios se hizo de manera independiente por revisores.

RESULTADOS: Ocho estudios originales se publicaron en el periodo de búsqueda, efectuados en diversos países de Europa, América y Asia. Los estudios usaron, principalmente, imágenes dermatoscópicas y modelos dicotómicos y multiclase basados en técnicas de aprendizaje automático y profundo. Se reportaron amplios intervalos de desempeño diagnóstico, con sensibilidades de, incluso, el 100% y especificidades entre 62.2 y 92.2%. Las principales limitaciones incluyeron sesgo demográfico hacia poblaciones caucásicas, tamaños muestrales reducidos y variabilidad en la calidad de las imágenes.

CONCLUSIONES: La bibliografía sugiere que la IA puede apoyar la detección temprana del melanoma. Sin embargo, persisten brechas relacionadas con la diversidad étnica y la falta de estudios prospectivos en contextos clínicos reales.

PALABRAS CLAVE: Neoplasias cutáneas; melanoma; inteligencia artificial; nevo displásico; diagnóstico diferencial.

Abstract

BACKGROUND: Melanoma has the highest mortality rate among skin cancers, with an annual increase of 3-5%. Differentiating melanoma from atypical nevi remains a complex clinical challenge, in which artificial intelligence (AI) may help reduce diagnostic errors and unnecessary biopsies.

OBJECTIVE: To map and characterize the scientific literature on the use of AI for differentiating melanoma from atypical melanocytic nevi.

METHODOLOGY: A scoping review was conducted in accordance with the PRISMA-ScR guidelines. Original articles published between 2015 and 2024 were searched in PubMed, ScienceDirect, and Medline. Study selection was performed independently by reviewers.

¹ Médica general, especialista en Epidemiología.

² Dermatóloga, MSc Epidemiología. Coordinadora del posgrado de Dermatología.

³ PhD. Epidemiología y Bioestadística. Docente investigador del grupo de Epidemiología y Bioestadística.

Universidad CES, Medellín, Colombia.

⁴ Médica general, especialista en Epidemiología, Universidad Pontificia Bolivariana y Universidad CES, Medellín, Colombia.

⁵ Dermatólogo, Medicáncer. Docente, Universidad Pontificia Bolivariana, Medellín, Colombia.

ORCID

<https://orcid.org/0000-0002-4780-1193>

<https://orcid.org/0000-0003-1633-6564>

<https://orcid.org/0000-0003-2209-9972>

<https://orcid.org/0000-0001-9734-0690>

<https://orcid.org/0000-0002-5699-9912>

Recibido: febrero 2026

Aceptado: junio 2026

Correspondencia

Carolina Posada Ramírez
posadar.carolina@uces.edu.co

Este artículo debe citarse como:

Posada-Ramírez C, Guerra-Espinosa V, Londoño-García A, Arias-Rodríguez C, Quirós-Gómez OI. Uso de inteligencia artificial para la diferenciación entre melanoma y nevo melanocítico atípico. Dermatol Rev Mex 2026; 70 (4): 508-519.

RESULTS: Eight original studies published within the search period were included, conducted across multiple countries in Europe, America, and Asia. Most studies used dermoscopic images and applied dichotomous and multiclass models based on machine learning and deep learning techniques. Wide ranges of diagnostic performance were reported, with sensitivities of up to 100% and specificities ranging from 62.2% to 92.2%. The main limitations included demographic bias toward Caucasian populations, small sample sizes, and variability in image quality.

CONCLUSIONS: The available literature suggests that AI may support the early detection of melanoma. However, gaps remain regarding ethnic diversity in datasets and the lack of prospective studies in real-world clinical settings.

KEYWORDS: Skin neoplasms; Melanoma; Artificial intelligence; Dysplastic nevus syndrome; Differential diagnosis.

ANTECEDENTES

El cáncer de piel es el tipo de cáncer más común en el mundo; 9500 personas se diagnostican cada año en Estados Unidos y se estima que 1 de cada 5 estadounidenses padecerá cáncer de piel en su vida; incluso, se ha descrito que alrededor de dos personas mueren por esta enfermedad cada hora.^{1,2} El cáncer de piel se divide en dos grandes grupos: el melanoma cutáneo maligno y el cáncer de piel no melanoma, que incluye los carcinomas basocelular y escamocelular.³

El melanoma representa menos del 2% del total de cánceres en todo el mundo; sin embargo, de los tipos de cáncer de piel, es el que tiene la mayor tasa de mortalidad. Esta enfermedad se ha incrementado un 3 a 5% cada año desde el 2020; la población de los países en vía de desarrollo tiene una menor tasa de supervivencia.^{4,5} El costo de la atención de los pacientes con melanoma es de 3.3 mil millones de dólares anuales en Estados Unidos.⁶ Un factor preponderante para una mayor supervivencia es el diagnóstico temprano porque los pacientes en estadio I tienen una tasa

de supervivencia a 10 años del 94-98%, mientras que en el estadio IV es del 10-15%.⁷

Los nevos atípicos son un subgrupo de nevos melanocíticos benignos que se caracterizan histológicamente por un trastorno arquitectural y una atipia citológica, que implica siempre su componente de unión.⁸ La bibliografía describe que no hay predominio por el melanoma para surgir específicamente desde el nevo atípico en comparación con el nevo común; sin embargo, el riesgo en ambos casos sigue siendo mínimo. La mayor parte de los nevos atípicos se mantienen estables en el tiempo o retroceden; implican un factor de riesgo de la aparición de melanoma; sin embargo, su transformación a éste es poco frecuente.^{9,10} La diferenciación de los nevos melanocíticos atípicos y melanomas es un importante desafío diagnóstico, incluso para los dermatoscopistas más experimentados, debido a la similitud de estas lesiones.¹¹

La inteligencia artificial (IA) ha emergido como un potente método de apoyo en la interpretación y precisión de imágenes, lo que puede ayudar a mejorar el flujo de trabajo de los médicos y

reducir los errores en la práctica clínica.¹² En dermatología, la aplicación de métodos de inteligencia computacional se remonta a 1987, con la introducción del reconocimiento de cáncer de piel a través de imágenes dermatoscópicas, y ha ganado una creciente atención a lo largo de los años porque permite analizar grandes volúmenes de datos, incluidas millones de imágenes que pueden analizar visualmente las condiciones de la piel, reconocer patrones y establecer diagnósticos basados en imágenes anteriores.^{13,14}

La IA se clasifica en varios subtipos: el aprendizaje automático (*machine learning*), que busca a partir de algoritmos y modelos de aprendizaje de la información basada en los datos proporcionados. De ésta se deriva el aprendizaje profundo (*deep learning*) en el que, mediante tecnología multicapa, analiza diferentes características para clasificar información. Ésta da origen a las redes neuronales convolucionales (*convolutional neural networks*), que automáticamente identifican patrones relevantes y están inspiradas en las redes neuronales del cerebro humano.¹⁵

Dados los retos diagnósticos de cáncer de piel melanoma y cómo diferenciarlo de un nevo melanocítico atípico en entornos de atención primaria, especialmente en países de bajos recursos, es importante avanzar en investigaciones que usen herramientas tecnológicas como facilitadoras de esta tarea, a fin de evitar biopsias innecesarias, lo que reduciría costos en el sistema de salud.^{5,16}

El objetivo de esta revisión de alcance fue identificar y analizar la bibliografía disponible acerca del uso de inteligencia artificial para diferenciar el melanoma del nevo melanocítico atípico, destacando investigaciones, enfoques y posibles vacíos en la bibliografía.

METODOLOGÍA

Formulación de la pregunta de investigación: se utilizó el marco PCC (población, concepto y

contexto), en el que la población correspondió a pacientes con melanoma o nevo melanocítico atípico, el concepto al uso de inteligencia artificial y el contexto a la diferenciación diagnóstica en comparación con métodos diagnósticos convencionales, como dermatoscopia e histopatología. A partir de este marco se formuló la pregunta: ¿cuál es el estado actual de la evidencia acerca del uso de la inteligencia artificial para diferenciar el melanoma del nevo melanocítico atípico?

Identificación de los estudios pertinentes: se incluyeron estudios originales y revisiones relacionadas con el diagnóstico de melanoma en piel y los nevos melanocíticos atípicos que usaran herramientas de inteligencia artificial y reportaran métricas de desempeño diagnóstico, siempre que consideraran la clasificación entre melanoma y nevos atípicos como categorías independientes. Se incluyeron artículos publicados entre 2015 y 2025 en inglés o español.

Selección de los artículos: se hizo una búsqueda bibliográfica entre el 1 julio y el 10 de agosto de 2025 en las bases de datos PubMed, ScienceDirect y Medline (EBSCO). El proceso metodológico se desarrolló de acuerdo con las directrices de PRISMA-ScR para revisiones de alcance.¹⁷ Las estrategias de búsqueda usadas en cada base de datos se describen en el **Cuadro 1**.

Análisis de la información

Los artículos identificados se importaron a la plataforma Rayyan para la detección de duplicados y proceso de selección. La revisión de títulos, resúmenes y texto completo la hicieron de manera independiente dos de los investigadores. La síntesis e interpretación de los resultados se llevaron a cabo con la participación de todos los autores.

Los metadatos de los artículos incluidos se organizaron mediante una tabla de extracción de

Cuadro 1. Estrategias de búsqueda

Estrategia de búsqueda	Base de datos	Registros recuperados (n)
("artificial intelligence" OR "machine learning" OR "deep learning") AND melanoma AND ("melanocytic nevus" OR "pigmented nevus") AND (diagnosis OR classification)	ScienceDirect	432
("Artificial Intelligence" [MeSH] OR "Machine Learning" [MeSH] OR "Deep Learning" [MeSH] OR "Neural Networks, Computer" [MeSH] OR artificial intelligence[tiab] OR machine learning[tiab] OR deep learning[tiab] OR convolutional neural network*[tiab] OR CNN[tiab]) AND ("Melanoma" [MeSH] OR melanoma[tiab]) AND ("Nevus, Pigmented" [MeSH] OR "Nevus, Melanocytic" [MeSH] OR melanocytic nevus[tiab] OR melanocytic nevi[tiab] OR pigmented nevus[tiab] OR pigmented nevi[tiab])	PubMed	69
(artificial intelligence or ai or a.i. or machine learning or deep learning or neural network) AND melanoma AND (nevus or nevi) AND (diagnosis or diagnosing or diagnostics or assessment or screening)	Medline (EBSCO)	247

Fuente. Elaboración propia.

datos, en la que los estudios se agruparon según autor, título y año de publicación. La extracción de la información se hizo por duplicado. De cada estudio se sintetizaron los siguientes aspectos clave:

Técnicas de IA utilizadas: se describen los enfoques de IA, incluidos modelos de aprendizaje automático, aprendizaje profundo y redes neuronales, entre otros.

Tipo de lesión cutánea: se especifica si los estudios incluyeron lesiones benignas, nevos melanocíticos atípicos o melanoma, así como los criterios de clasificación.

Resultados del estudio: se informan las principales métricas de desempeño diagnóstico, como la precisión, sensibilidad, especificidad y área bajo la curva, cuando estuvieron disponibles.

Limitaciones identificadas: se documentan las limitaciones reportadas, incluido el tamaño de la muestra, la calidad de las imágenes, sesgo demográfico y otras consideraciones metodológicas relevantes.

Debido a que la investigación se desarrolló a partir de fuentes secundarias, no fue posible intervenir directamente en los posibles sesgos presentes en los datos originales. Sin embargo, se adoptó un enfoque crítico y riguroso, mediante la aplicación estandarizada de los criterios de elegibilidad previamente definidos. Con el fin de garantizar la consistencia en la extracción de datos, se hizo una verificación cruzada aleatoria de una muestra de los estudios incluidos, orientada a minimizar errores de transcripción.

Este estudio se clasifica sin riesgo de acuerdo con la resolución 8439 de 1993 del Ministerio de Salud de Colombia. El estudio contó con el aval del Comité de Ética Universidad CES (Acta 264 del 24 de abril de 2025).

RESULTADOS

Se encontraron 752 artículos, de los que 116 eran duplicados, por lo que se excluyeron. Los 636 restantes se revisaron por título y resumen, se excluyeron 592 debido a inconsistencia con el objetivo de este estudio. Se incluyeron 44 artículos para la fase de lectura completa, de los

que se incluyeron 8 por cumplir con los criterios de elegibilidad. **Figura 1**

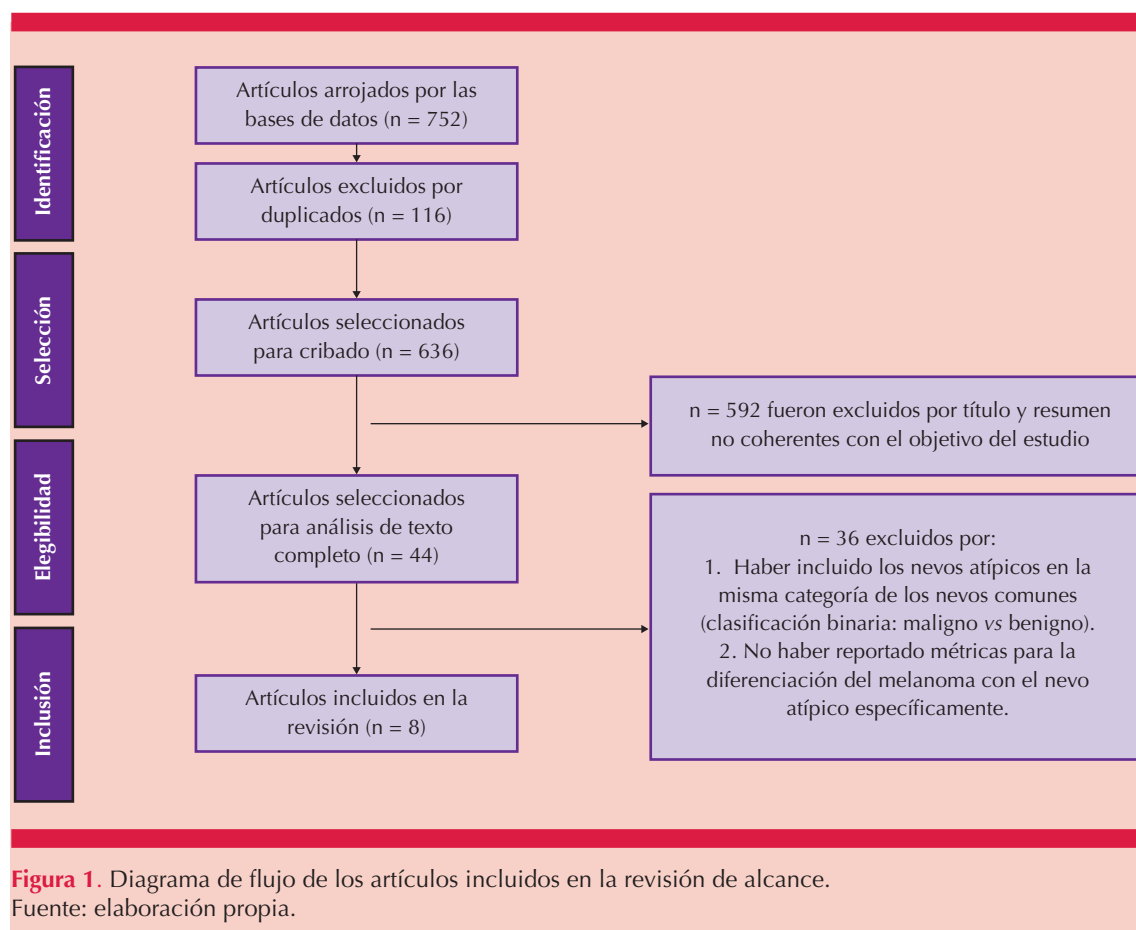
Los estudios incluidos se llevaron a cabo en diversos países: Italia, Polonia, Rumania, España, Francia, Chile, Estados Unidos, India e Irak, lo que refleja un uso internacional de inteligencia artificial en el diagnóstico de lesiones melano-cíticas.

En cuanto al enfoque de clasificación, se identificaron dos tipos de modelos. Los dicotómicos se basaron en la discriminación entre melanoma y nevos atípicos, como lo describieron los estudios de Agüero, Tognetti y Rastgoo,^{16,18,19} mientras que los otros estudios implementaron modelos

multicategoricos, en los que el melanoma se comparó de forma individual con distintos tipos de lesiones melanocíticas (nevos comunes, atípicos y subtipos, como Spitz y azules); se evitó agrupar las lesiones en un único grupo benigno.

En cuanto al tamaño muestral, hubo una diferencia considerable entre los estudios, con muestras desde 61 láminas histológicas²⁰ y otras con, incluso, 1114 imágenes.¹⁶ Asimismo, se encontró que la mayor parte de los estudios utilizaron imágenes dermatoscópicas, a excepción de uno que se centró en histopatología digital.²⁰

Los enfoques de inteligencia artificial usados fueron diversos; se incluyeron métodos de apren-



dizaje automático y aprendizaje profundo. Las métricas de desempeño reportadas con más frecuencia fueron sensibilidad, especificidad, área bajo la curva, precisión y exactitud. Las sensibilidades informadas variaron del 81.5 al 100%, mientras que las especificidades variaron del 62.2 al 92.2%.^{18,20,21,22} El valor más alto de área bajo la curva (0.975) lo reportó un estudio que usó un modelo basado en redes neuronales.²¹

Las principales limitaciones reportadas se relacionan con el sesgo demográfico, debido a que la mayor parte de los conjuntos de datos provienen de poblaciones caucásicas, predominantemente de fototipos I-III según la clasificación de Fitzpatrick, como el estudio de Agüero y su grupo.¹⁸ Asimismo, varios estudios describen problemas asociados con artefactos, como vello, burbujas y variaciones en la iluminación, así como el tipo y calidad de la imagen.^{19,21,23} Otra limitación recurrente corresponde al tamaño reducido de las muestras analizadas.^{18,22} Asimismo, Moldovanu y colaboradores señalan que el solapamiento de características entre el melanoma y el nevo melanocítico atípico continúa representando un desafío para su diferenciación precisa.²¹ El **Cuadro 2** muestra la extracción de datos.

DISCUSIÓN

Esta revisión de alcance evidencia que la mayor parte de los estudios incluidos provienen de países con mayor capacidad tecnológica, lo que sugiere desigualdades en la generación de evidencia y limita la generalización de los hallazgos a otros contextos.

Cinco de los estudios se centraron en el uso de aprendizaje automático^{18,19,22,23,24} para el adiestramiento de los modelos; se compararon los distintos algoritmos con el fin de identificar el mejor desempeño para la diferenciación, mientras que los otros tres incluyeron tecnología de IA más reciente, como el aprendizaje

profundo.^{16,20,21} Llama la atención que, pese a lo esperado, los modelos de aprendizaje automático tradicional alcanzaron rendimientos similares, sin diferencias marcadas frente a las técnicas más avanzadas. Este es el caso del modelo diseñado por Jaworek-Korjakowska y Kłeczek, que obtuvo métricas de sensibilidad y especificidad altas para diferenciar entre los subtipos de lesiones melanocíticas, como el nevo de Spitz, Clark y el melanoma.²²

Los estudios reportaron diversas métricas para evaluar el desempeño de los modelos, entre ellas la sensibilidad, especificidad, precisión, área bajo la curva y exactitud. De manera consistente la sensibilidad mostró los valores más elevados, lo que sugiere un potencial uso de estas herramientas como apoyo al tamizaje de melanoma. Sin embargo, las especificidades fueron generalmente más bajas, lo que indica menor capacidad para descartar correctamente los nevos melanocíticos atípicos.

En cuanto al tipo de lesiones estudiadas, la mayor parte de los modelos se adiestraron con imágenes dermatoscópicas, a excepción de los estudios de Moldovanu y Snyder, que usaron imágenes clínicas tomadas con cámaras digitales comunes y láminas histopatológicas, respectivamente.^{20,21} Snyder y colaboradores diseñaron un modelo basado en redes neuronales convolucionales (CNN) adiestradas en características de morfología celular, específicamente en núcleos y citoplasma, lo que sustenta que un diagnóstico correcto en fase temprana permite un tratamiento adecuado que mejora la tasa de supervivencia, incluso, 10 veces, y reduce los costos de tratamiento cien veces.²⁰

Rastgoo¹⁹ y Brar²³ coinciden en que la textura de las lesiones cutáneas, definida como cambios epidérmicos visibles en las imágenes, aporta más información diagnóstica que otras características, como el color o la forma, que pueden variar considerablemente según las condiciones

Cuadro 2. Características de los estudios incluidos

Estudio (año)	Modelo de IA	País	Tamaño muestral y tipo de lesiones	Métricas de desempeño reportadas	Limitaciones principales
Agüero et al. (2024)	Aprendizaje automático basado en biomarcadores de imagen	Chile, Estados Unidos	78 imágenes (39 melanoma, 39 nevos atípicos)	Sensibilidad 81.6%; especificidad 67.3%	Cohorte pequeña; sesgo demográfico (fototipos I-III); aplicabilidad limitada
Surówka y Ogorzalek (2019)	Máquina de vectores de soporte (kernel gaussiano)	Polonia	385 lesiones (melanoma y nevos atípicos-comunes)	Área bajo la curva ROC 0.87-0.94	Dificultad de validación externa; efecto de compresión de imagen
Moldovanu et al. (2021)	Red neuronal artificial (<i>feedforward</i>)	Rumania	1095 imágenes (455 melanoma, 640 nevos)	Sensibilidad 100%; área bajo la curva ROC 0.98	Solapamiento de características; variabilidad en tipo y calidad de imagen
Tognetti et al. (2021)	Redes neuronales convolucionales profundas híbridas con datos clínicos	Italia (multicéntrico europeo)	1114 casos (359 melanoma, 755 nevos atípicos)	Área bajo la curva ROC 0.90; sensibilidad 86.5%; especificidad 73.6%	Población caucásica; falta de validación prospectiva
Rastgoo et al. (2015)	Random Forest, <i>support vector machine</i> y <i>boosting</i>	España, Francia	180 lesiones (90 melanoma, 90 nevos displásicos)	Sensibilidad 92-98%; especificidad 68-70%	Exclusión de imágenes por artefactos; conjunto de datos limitado
Snyder et al. (2022)	Aprendizaje profundo (ResNet50)	Estados Unidos	61 láminas histológicas (melanoma y nevos)	Sensibilidad melanoma 100%; precisión 76.2%	Muestra pequeña; adiestramiento en casos no ambiguos
Jaworek-Korjakowska y Kleczek (2016)	Máquina de vectores de soporte, regresión logística, árboles, k-NN	Polonia	300 imágenes (melanoma y subtipos de nevos)	Área bajo la curva ROC 0.97-0.99	Desequilibrio de clases; validez externa limitada
Brar et al. (2024)	Diagnóstico asistido por computadora basado en máquina de vectores de soporte	India, Irak, Estados Unidos	200 imágenes (melanoma, nevos atípicos y comunes)	Sensibilidad 96%; especificidad 77.5%; área bajo la curva ROC 0.93	Similitud entre lesiones; artefactos y bajo contraste

Fuente: elaboración propia.

de iluminación o el dispositivo usado, lo que sugiere que la textura debería considerarse un componente importante en el desarrollo de futuros modelos de inteligencia artificial.^{19,23}

Mientras que una proporción considerable de los estudios identificados en la bibliografía trató el problema mediante un enfoque binario y clasificó a las lesiones como benignas o malignas, como el estudio de Paoli y su grupo, otros trabajos como el de Jaworek-Korjakowska y Kłeczek ampliaron estos modelos hacia esquemas multiclase, que permiten una identificación más precisa de los distintos subtipos de lesiones melanocíticas atípicas, como el nevo de Spitz, de Clark y el azul.^{22,25}

Por último, dos hallazgos destacan por su carácter innovador. Por un lado, para solucionar la falta de transparencia de los modelos convencionales tipo “caja negra”, Agüero y su grupo implementaron el uso de biomarcadores de imagen, que permiten que el médico comprenda el proceso mediante el que se llega a la decisión diagnóstica.

Surówka y colaboradores demostraron que el uso de descriptores *wavelet* en imágenes de menor resolución posibilita la implementación de estos sistemas en dispositivos móviles, lo que representa una ventaja relevante para su aplicación en entornos con recursos limitados sin afectar el rendimiento diagnóstico a través de la telemedicina.^{18,24}

La inteligencia artificial muestra potencial como método de apoyo para el diagnóstico no invasivo del melanoma, con posibles beneficios en el tamizaje, la reducción de biopsias innecesarias y la optimización de recursos, siempre como complemento del criterio clínico del especialista.^{26,27}

Este mapeo de la bibliografía evidencia que el nevo melanocítico atípico se ha explorado menos como categoría específica, a pesar de

representar el mayor desafío diagnóstico. La ausencia de estudios prospectivos que evalúen el efecto real de estas herramientas impide determinar cómo influyen a largo plazo en los resultados de los pacientes.

Las limitaciones de esta revisión incluyen posibles sesgos de publicación y selección, así como una alta heterogeneidad en los tamaños muestrales y metodologías de los estudios incluidos.

CONCLUSIONES

Esta revisión de alcance permite caracterizar el estado actual de la evidencia acerca del uso de la inteligencia artificial en la diferenciación entre melanoma y nevo melanocítico atípico y demuestra su potencial como método de apoyo al diagnóstico no invasivo. La bibliografía disponible sugiere que estas tecnologías pueden contribuir a la detección temprana del melanoma y a la optimización de recursos en los sistemas de salud, sin sustituir el criterio clínico del especialista. No obstante, el mapeo realizado revela vacíos relevantes en la evidencia, particularmente en relación con la limitada exploración del nevo melanocítico atípico como afección diagnóstica independiente, la falta de estudios en fototipos no caucásicos y la escasez de estudios prospectivos en contextos clínicos reales.

DECLARACIONES

Conflicto de intereses

Los autores declaran no tener conflictos de intereses.

Financiamiento

Esta investigación no recibió ayudas específicas provenientes de agencias del sector público, sector comercial o entidades sin ánimo de lucro.

Uso de IA

Este manuscrito contó con el apoyo de ChatGPT (OpenAI) para la revisión de estilo de algunas frases y para la traduc-

ción del resumen al inglés. El contenido científico, el análisis de la bibliografía y las conclusiones son responsabilidad exclusiva de los autores.

Contribución de los autores

Carolina Posada Ramírez y Valeria Guerra Espinosa: identificación de temas, interrogantes o problemas que ameritan investigación; determinación del diseño del estudio, incluida la selección de participantes, materiales, entornos, características de los datos, recolección de datos y técnicas de medición y análisis; búsqueda y revisión de la bibliografía; redacción del trabajo y revisión crítica en busca de contenido intelectual importante. *Carolina Posada Ramírez, Valeria Guerra Espinosa y Oscar Iván Quirós:* definición de estrategias de búsqueda. *Carolina Posada Ramírez, Valeria Guerra Espinosa y Oscar Iván Quirós:* contribuciones sustanciales a la concepción y al diseño del trabajo, al análisis y a la interpretación de datos para el trabajo. *Oscar Iván Quirós:* formulación de preguntas de investigación e hipótesis; *Carolina Posada Ramírez, Valeria Guerra Espinosa, Ángela Londoño García, Camilo Arias Rodríguez y Oscar Iván Quirós:* aprobación final del artículo.

Declaración de derechos humanos y de los animales

No se realizó ningún estudio con sujetos humanos o animales.

Consentimiento informado

No aplica porque no se estudió el caso de un paciente.

Referencias clave

1. Tognetti L, Bonechi S, Andreini P, et al. A new deep learning approach integrated with clinical data for the dermoscopic differentiation of early melanomas from atypical nevi. *J Dermatol Sci* 2021; 101 (2): 115-122. <https://doi.org/10.1016/j.jdermsci.2020.11.009>
2. Agüero R, Buchanan KL, Navarrete-Dechent C, et al. The impact of melanoma imaging biomarker cues on detection sensitivity and specificity in melanoma versus clinically atypical nevi. *Cancers (Basel)* 2024; 16 (17): 3077. <https://doi.org/10.3390/cancers16173077>
3. Rastgoo M, Garcia R, Morel O, Marzani F. Automatic differentiation of melanoma from dysplastic nevi. *Comput Med Imaging Graph* 2015; 43: 44-52. <https://doi.org/10.1016/j.compmedimag.2015.02.011>
4. Jones OT, Matin RN, van der Schaar M, et al. Artificial intelligence and machine learning algorithms for early detection of skin cancer in community and primary care settings: a systematic review. *Lancet Digit Health* 2022; 4 (6): e466-e476. [https://doi.org/10.1016/S2589-7500\(22\)00023-1](https://doi.org/10.1016/S2589-7500(22)00023-1)

5. Joshi UM, Kashani-Sabet M, Kirkwood JM. Cutaneous melanoma: a review. *JAMA* 2025; 334 (23): 2113-2125. <https://doi.org/10.1001/jama.2025.13074>

Permisos

Las Figuras y Cuadros son de elaboración propia.

REFERENCIAS

1. American Academy of Dermatology Association. Skin cancer. Schaumburg (IL): American Academy of Dermatology; 2024.
2. O'Leary MA, Wang SJ. Epidemiology and prevention of cutaneous cancer. *Otolaryngol Clin North Am* 2021; 54 (2): 247-257. <https://doi.org/10.1016/j.otc.2020.11.001>
3. Meijis M, Herrera A, Acosta A, de Vries E. Burden of skin cancer in Colombia. *Int J Dermatol* 2022; 61 (8): 1003-1011. <https://doi.org/10.1111/ijd.16077>
4. de Vries E, Sierra M, Piñeros M, Loria D, Forman D. The burden of cutaneous melanoma and status of preventive measures in Central and South America. *Cancer Epidemiol* 2016; 44 (Supl 1): S100-S109. <https://doi.org/10.1016/j.canep.2016.02.005>
5. Jones OT, Matin RN, van der Schaar M, et al. Artificial intelligence and machine learning algorithms for early detection of skin cancer in community and primary care settings: a systematic review. *Lancet Digit Health* 2022; 4 (6): e466-e476. [https://doi.org/10.1016/S2589-7500\(22\)00023-1](https://doi.org/10.1016/S2589-7500(22)00023-1)
6. Bolick NL, Geller AC. Epidemiology of melanoma. *Hematol Oncol Clin North Am* 2021; 35 (1): 57-72. <https://doi.org/10.1016/j.hoc.2020.08.011>
7. Alsayyah A. Differentiating between early melanomas and melanocytic nevi: a state-of-the-art review. *Pathol Res Pract* 2023; 249: 154734. <https://doi.org/10.1016/j.prp.2023.154734>
8. Menzinger S, Merat R, Kaya G. Dysplastic nevi and superficial borderline atypical melanocytic lesions: description of an algorithmic clinico-pathological classification. *Dermatopathology* 2025; 12 (1): 3. <https://doi.org/10.3390/dermatopathology12010003>
9. Joshi UM, Kashani-Sabet M, Kirkwood JM. Cutaneous melanoma: a review. *JAMA* 2025; 334 (23): 2113-2125. <https://doi.org/10.1001/jama.2025.13074>
10. Emiroglu N, Sallahoglu K, Cengiz FP, et al. Three years dermoscopic follow-up of atypical nevi. *Dermatol Ther* 2020; 33 (1): e13205. <https://doi.org/10.1111/dth.13205>
11. Tognetti L, Cinotti E, Moscarella E, et al. Impact of clinical and personal data in the dermoscopic differentiation between early melanoma and atypical nevi. *Dermatol Pract Concept* 2018; 8 (4): 324-327. <https://doi.org/10.5826/dpc.0804a16>
12. Grech V, Cuschieri S, Eldawlatly AA. Artificial intelligence in medicine and research: the good, the bad, and the ugly. *Saudi J Anaesth* 2023; 17 (3): 401-406. https://doi.org/10.4103/sja.sja_344_23

13. Patel S, Wang JV, Motaparathi K, Lee JB. Artificial intelligence in dermatology for the clinician. *Clin Dermatol* 2021; 39 (4): 667-672. <https://doi.org/10.1016/j.clindermatol.2021.03.012>
14. Curiel-Lewandrowski C, Novoa R, Berry E, Celebi ME, Codella N, Giuste F, et al. Artificial intelligence approach in melanoma. In: *Melanoma*. Cham: Springer; 2019: 599-628. https://doi.org/10.1007/978-1-4614-7147-9_43
15. Bucio SG. Inteligencia artificial en dermatología. *Dermatol Rev Mex* 2023; 67 (6). <https://doi.org/10.24245/drm/bmu.v67i6.9327>
16. Tognetti L, Bonechi S, Andreini P, et al. A new deep learning approach integrated with clinical data for the dermoscopic differentiation of early melanomas from atypical nevi. *J Dermatol Sci* 2021; 101 (2): 115-122. <https://doi.org/10.1016/j.jdermsci.2020.11.009>
17. Tricco AC, Lillie E, Zarin W, et al. PRISMA extension for scoping reviews (PRISMA-ScR): checklist and explanation. *Ann Intern Med* 2018; 169 (7): 467-473. <https://doi.org/10.7326/M18-0850>
18. Agüero R, Buchanan KL, Navarrete-Dechent C, et al. The impact of melanoma imaging biomarker cues on detection sensitivity and specificity in melanoma versus clinically atypical nevi. *Cancers (Basel)* 2024; 16 (17): 3077. <https://doi.org/10.3390/cancers16173077>
19. Rastgoo M, Garcia R, Morel O, Marzani F. Automatic differentiation of melanoma from dysplastic nevi. *Comput Med Imaging Graph* 2015; 43: 44-52. <https://doi.org/10.1016/j.compmedimag.2015.02.011>
20. Snyder AN, Zhang D, Dreesen SL, et al. Histologic screening of malignant melanoma, Spitz, dermal and junctional melanocytic nevi using a deep learning model. *Am J Dermatopathol* 2022; 44 (9): 650-657. <https://doi.org/10.1097/DAD.0000000000002232>
21. Moldovanu S, Obreja CD, Biswas KC, Moraru L. Towards accurate diagnosis of skin lesions using feedforward back propagation neural networks. *Diagnostics* 2021; 11 (6): 936. <https://doi.org/10.3390/diagnostics11060936>
22. Jaworek-Korjakowska J, Kłeczek P. Automatic classification of specific melanocytic lesions using artificial intelligence. *Biomed Res Int* 2016; 2016: 8934242. <https://doi.org/10.1155/2016/8934242>
23. Brar KK, Goyal B, Dogra A, et al. Multi-class skin cancer detection using fusion of textural features based CAD tool. *Comput Mater Contin* 2024; 81 (3): 4217-4263. <https://doi.org/10.32604/cmc.2024.052548>
24. Surówka G, Ogorzalek M. Resolution invariant wavelet features of melanoma studied by SVM classifiers. *PLoS One* 2019; 14 (2): e0211318. <https://doi.org/10.1371/journal.pone.0211318>
25. Paoli J, Pölonen I, Salmivuori M, et al. Hyperspectral imaging for non-invasive diagnostics of melanocytic lesions. *Acta Derm Venereol* 2022; 102: adv00815. <https://doi.org/10.2340/actadv.102.2045>
26. Du-Harpur X, Watt FM, Luscombe NM, Lynch MD. What is AI? Applications of artificial intelligence to dermatology. *Br J Dermatol* 2020; 183 (3): 423-430. <https://doi.org/10.1111/bjd.18880>
27. Brinker TJ, Hekler A, Enk AH, et al. Deep neural networks are superior to dermatologists in melanoma image classification. *Eur J Cancer* 2019; 119: 11-17. <https://doi.org/10.1016/j.ejca.2019.05.023>

EVALUACIÓN

1. ¿Cuál es la tendencia general observada en las métricas de desempeño de los modelos de inteligencia artificial analizados?
 - a) la especificidad es consistentemente superior a la sensibilidad
 - b) la sensibilidad muestra los valores más elevados en comparación con la especificidad
 - c) la sensibilidad y la especificidad son inferiores al 50%
 - d) los modelos no logran superar la precisión del azar
2. ¿Cuál es el principal sesgo demográfico identificado en los conjuntos de datos utilizados para entrenar la IA?
 - a) poblaciones de fototipos IV a VI
 - b) poblaciones exclusivamente asiáticas
 - c) poblaciones caucásicas con fototipos I a III
 - d) poblaciones indígenas de América Latina
3. ¿Cuál es la implicación clínica más importante de que los modelos de IA muestren

- una sensibilidad cercana al 100% pero una especificidad significativamente menor?
- a) los modelos son ideales para confirmar diagnósticos definitivos y evitar cirugías
 - b) las herramientas son altamente efectivas para el tamizaje, aunque pueden aumentar la cantidad de falsos positivos
 - c) la IA es capaz de descartar correctamente los nevos atípicos en la mayoría de los casos
 - d) el desempeño de la IA es superior al del dermatólogo en sensibilidad y en especificidad clínica
4. ¿Cuál es la principal justificación económica y clínica para priorizar el diagnóstico del melanoma en estadio I frente a estadios avanzados?
- a) el tratamiento del estadio I requiere tecnologías de IA más costosas
 - b) la supervivencia en estadio IV es comparable si se utiliza inmunoterapia moderna
 - c) el diagnóstico temprano permite una supervivencia a 10 años superior al 94% y reduce los costos hasta cien veces
 - d) los costos de atención se mantienen constantes independientemente del estadio al diagnóstico.
5. ¿Por qué la clasificación binaria simple (maligno vs benigno) suele considerarse insuficiente en el estudio de lesiones melanocíticas?
- a) porque el melanoma siempre muestra características inequívocas de malignidad
 - b) porque los nevos atípicos comparten características con el melanoma, por lo que requieren un análisis como categoría independiente
 - c) debido a que la IA sólo funciona correctamente cuando se analizan lesiones comunes
 - d) porque los nevos comunes y los atípicos tienen el mismo comportamiento biológico
6. En el estudio de Snyder y su grupo, ¿qué tipo de IA se utilizó para mejorar la precisión diagnóstica desde una perspectiva histopatológica?
- a) análisis automatizado de macrofotografía clínica
 - b) algoritmos basados exclusivamente en la edad y el sexo del paciente
 - c) redes neuronales convolucionales adiestradas en morfología celular
 - d) sistemas de apoyo basados en la saturación del color en dermatoscopia
7. ¿Qué obstáculo técnico relacionado con la calidad de la imagen se reporta frecuentemente como una limitación para el desempeño de los algoritmos de IA?
- a) la alta resolución de las cámaras digitales modernas
 - b) artefactos como vello, burbujas de aire o variaciones en la iluminación
 - c) el uso excesivo de luz polarizada en la captura de las imágenes
 - d) la homogeneidad en los protocolos de captura fotográfica clínica
8. ¿Cuál es la conclusión fundamental de la revisión acerca del papel del dermatólogo frente al avance de la inteligencia artificial?
- a) el dermatólogo será reemplazado por sistemas de diagnóstico asistido por computadora
 - b) el juicio clínico debe quedar sujeto a los resultados de sensibilidad de la IA
 - c) la IA funciona como un método de apoyo que no sustituye el criterio clínico del especialista

- d) el uso de IA hace innecesaria la correlación clínico-patológica en el melanoma
9. ¿Cuál es la principal brecha de evidencia identificada que impide la implementación inmediata de estos modelos en la práctica clínica real?
- a) la falta de modelos de aprendizaje automático disponibles en el mercado
 - b) la escasez de estudios prospectivos realizados en contextos clínicos reales fuera de entornos controlados
 - c) la imposibilidad de adiestrar redes neuronales con imágenes histopatológicas
 - d) la baja tasa de mortalidad del melanoma hace innecesaria la tecnología
10. Según los estudios que integran datos clínicos con imágenes (modelos híbridos), ¿cuál es el valor agregado de incluir variables como la edad o el sexo en el algoritmo?
- a) reemplazar la necesidad de capturar imágenes dermatoscópicas de alta resolución
 - b) reducir el tiempo de procesamiento de la red neuronal convolucional
 - c) optimizar el desempeño diagnóstico al contextualizar las características morfológicas de la lesión con el perfil del paciente
 - d) permitir que el algoritmo funcione sin necesidad de una fase de adiestramiento previa

El Consejo Mexicano de Dermatología, A.C. otorgará dos puntos con validez para la recertificación a quienes envíen correctamente contestadas las evaluaciones que aparecen en cada número de *Dermatología Revista Mexicana*.

El lector deberá enviar todas las evaluaciones de 2026 a la siguiente dirección electrónica: articulos@nietoeditores.com.mx

Cada evaluación debe ser personalizada y única.

Fecha límite de recepción de evaluaciones: 15 de enero de 2027