Clasificación inteligente de lesiones en la piel mediante descriptores y transformadas matemáticas.

Intelligent Classification of Skin Lesions Using Descriptors and Mathematical Transforms.

Luis Felipe López Ávila (1).
Centro de Investigación Científica y de Educación Superior de Ensenada, B. C. (CICESE), Carretera Ensenada-Tijuana No. 3918, Zona Playitas, Ensenada 22860, B. C., México.
lopezf@cicese.edu.mx.

Esperanza Guerra Rosas (2). Centro de Investigación Científica y de Educación Superior de Ensenada, B. C. (CICESE), Carretera Ensenada-Tijuana No. 3918, Zona Playitas, Ensenada 22860, B. C., México.
eguerra@cicese.edu.mx.

Josué Álvarez Borrego* (3). Centro de Investigación Científica y de Educación Superior de Ensenada, B. C. (CICESE), Carretera Ensenada-Tijuana No. 3918, Zona Playitas, Ensenada 22860, B. C., México.
josue@cicese.edu.mx.

Esbanyely Garza Flores (4). Centro de Investigación Científica y de Educación Superior de Ensenada, B. C. (CICESE), Carretera Ensenada-Tijuana No. 3918, Zona Playitas, Ensenada 22860, B. C., México.
egarza@cicese.edu.mx.

*corresponding author.

Artículo recibido en septiembre 12, 2026; aceptado en octubre 10, 2026.

Resumen.

La piel es el órgano más grande del cuerpo y, a la vez, una de las primeras señales de nuestra salud. Detectar a tiempo una lesión maligna puede marcar la diferencia entre un tratamiento sencillo y una enfermedad grave. En nuestras investigaciones desarrollamos un método que enseña a la computadora a distinguir entre ocho tipos de lesiones de la piel a partir de fotografías digitales. La idea central es novedosa: en lugar de darle a la máquina la imagen completa, la convertimos en una "huella" numérica, una firma matemática, que resume las características esenciales de cada lesión y que no cambia aunque la fotografía esté rotada, alejada o desplazada. Con esa estrategia obtuvimos clasificaciones muy precisas usando incluso una computadora portátil común, lo que abre la puerta a herramientas de apoyo al diagnóstico dermatológico que sean rápidas, no invasivas y económicas.

Palabras clave: Apoyo al diagnóstico, clasificaciones, firma matemática, lesiones de la piel.

Abstract.

The skin is the largest organ in the body and one of the earliest indicators of our health. Detecting a malignant lesion early can be the difference between a simple treatment and a serious disease. In our research, we developed a method that teaches computers to distinguish among eight types of skin lesions from digital photographs. The core idea is novel: instead of feeding the machine the whole image, we turn it into a numerical "fingerprint", a mathematical signature, that summarizes the essential features of each lesion and does not change even if the photograph is rotated,

zoomed, or shifted. With this strategy, we achieved highly accurate classifications using even an ordinary laptop, paving the way toward diagnostic-support tools for dermatology that are fast, non-invasive, and inexpensive.

Keywords: Classifications, diagnostic-support, mathematical signature, skin lesions.

1. El problema: una piel que habla, pero que no siempre entendemos.

La piel nos cubre, nos protege del ambiente y, muchas veces, nos avisa cuando algo anda mal. Con el paso del tiempo y la exposición al sol aparecen manchas, lunares y crecimientos de todo tipo. La mayoría son inofensivos, pero algunos no lo son. El cáncer de piel es una de las enfermedades más frecuentes en el mundo, y su detección temprana es determinante para el pronóstico del paciente.

El reto es que muchas lesiones se parecen entre sí. Un lunar común (nevus melanocítico) puede confundirse a simple vista con un melanoma, el más agresivo de los cánceres de piel. Existen además otras lesiones frecuentes que conviene diferenciar: el carcinoma basocelular, el carcinoma de células escamosas, la queratosis actínica, la queratosis benigna, el dermatofibroma y las lesiones vasculares. En total, nuestro trabajo aborda los ocho tipos de lesiones que se resumen en la Tabla 1. Distinguirlas requiere experiencia, y el ojo humano tiene límites.

Tabla 1. Los ocho tipos de lesiones de la piel analizados en nuestros estudios.

Abreviación	Lesión	Naturaleza
BCC	Carcinoma basocelular	Cáncer (el más frecuente; crecimiento lento)
SCC	Carcinoma de células escamosas	Cáncer (el segundo más común)
MEL	Melanoma	Cáncer (el más agresivo)
AK	Queratosis actínica	Lesión precancerosa (por exposición solar)
BKL	Queratosis benigna	Benigna
DF	Dermatofibroma	Benigna
NV	Lunar / nevus melanocítico	Benigna (la más común)
VASC	Lesión vascular	Benigna (de los vasos sanguíneos)

Aquí es donde entra la inteligencia artificial. Si se le muestran suficientes ejemplos, una computadora puede aprender a reconocer patrones visuales que a nosotros nos cuesta describir con palabras. Nuestro trabajo se sitúa justo en ese punto: usar el procesamiento de imágenes y la inteligencia artificial para apoyar el diagnóstico dermatológico de forma automática, rápida y sin necesidad de procedimientos invasivos.

2. La idea central: de la imagen a la “huella” matemática.

La forma más popular de clasificar imágenes con computadoras son las redes neuronales convolucionales, muy potentes pero también muy exigentes en cómputo. Además tienen una debilidad importante para este problema: si la misma lesión aparece girada, más lejos o descentrada en la foto, la máquina puede “verla” como algo distinto. En imágenes de piel, donde las lesiones varían enormemente en tamaño, forma y orientación, lo cual representa un reto a considerar.

Nuestra propuesta toma otro camino. En lugar de trabajar con la imagen completa, la transformamos en una firma: una secuencia de números que funciona como una huella dactilar de la lesión. Dos fueron los principios que guiaron el diseño de esa firma:

- **Que resuma lo esencial.** La firma condensa la información de color, textura y estructura de la lesión en un vector de apenas cientos de valores, mucho más ligero de procesar que una fotografía entera.
- **Que sea estable.** La huella debe ser prácticamente la misma aunque la fotografía cambie de escala, esté desplazada o rotada. Esta propiedad, llamada invariancia, es la que da robustez al método.Para lograr esa

estabilidad recurrimos a herramientas matemáticas conocidas como transformadas integrales, cada una encargada de dar consistencia a la firma frente a un tipo de variación:

- La **transformada de Fourier** aporta estabilidad frente a desplazamientos (que la lesión no esté centrada).
- La **transformada de Mellin** aporta estabilidad frente a cambios de tamaño (que la foto se haya tomado más cerca o más lejos).
- La **transformada radial de Hilbert** aporta estabilidad frente a rotaciones (que la lesión aparezca girada).

A esto sumamos un descriptor de textura llamado Patrón Binario Local (LBP), que capta detalles finos de la superficie de la piel; bordes, manchas, zonas rugosas o lisas, comparando cada punto de la imagen con sus vecinos.

Un detalle que resultó clave: en vez de analizar la imagen en blanco y negro, la separamos en sus canales de color rojo, verde y azul, más una versión en escala de grises, y calculamos la firma en cada uno. Cada canal aporta información distinta; el rojo resalta la pigmentación, el verde las estructuras intermedias y el azul las texturas finas, y juntarlos permite captar diferencias muy sutiles entre lesiones. El resultado de todo este proceso es una firma de 444 valores por imagen.

3. Cómo lo hicimos y qué encontramos.

Para entrenar y poner a prueba el método usamos un banco público de imágenes dermatológicas reconocido internacionalmente (la colaboración ISIC, en su edición 2019), que reúne miles de fotografías de ocho tipos de lesiones.

Primero depuramos las imágenes con demasiado "ruido"; vellos, marcas de regla u otros objetos que dificultan el análisis. Como esto redujo mucho el material disponible y algunas clases quedaban con muy pocos ejemplos, aplicamos una técnica llamada aumento de datos: generamos variantes de cada imagen rotándola y cambiándole el tamaño de forma controlada. Así conseguimos un conjunto amplio y equilibrado, con el mismo número de ejemplos por cada tipo de lesión (1 840 imágenes por clase) para evitar que la máquina se sesgara hacia las clases más numerosas.

Nuestra investigación avanzó en dos etapas complementarias.

3.1 Primera etapa: probar muchos "cerebros" clasificadores.

Una vez convertidas las imágenes en firmas, entrenamos once modelos distintos de inteligencia artificial; variantes de máquinas de soporte vectorial (SVM), del método de vecinos más cercanos (k-NN) y de clasificadores de conjunto, para ver cuál aprovechaba mejor las firmas. Todos dieron resultados muy satisfactorios, como se ve en la figura 1, y el mejor fue un modelo llamado *subspace k-NN*. Para asegurarnos de que estos números no eran fruto del azar, repetimos todo el proceso 30 veces y reportamos los promedios con su margen de variación.
El mejor clasificador de esta etapa, el *subspace k-NN*, logró resultados casi perfectos en las cuatro medidas que usamos habitualmente para evaluar un sistema de diagnóstico (Tabla 2).

Tabla 2. Desempeño del mejor modelo de la primera etapa (*subspace k-NN*) sobre el conjunto de prueba, promediado en las ocho lesiones tras 30 repeticiones.

Métrica	Descripción de la medición	Resultado
Exactitud	Aciertos otals del sistema	99.99 %
Sensibilidad	Detectar la lesión cuando sí está presente	99.96 %
Especificidad	No dar falsas alarmas cuando no está	99.99 %
Precisión	Confiabilidad de cada diagnóstico positivo	99.95 %

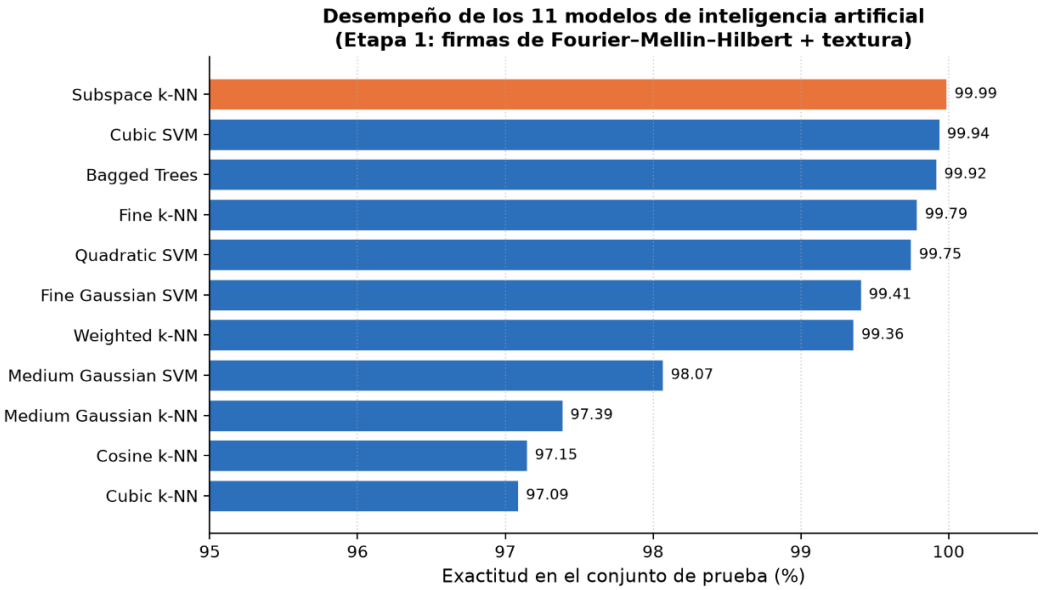


Figura 1. Exactitud alcanzada por los once modelos de inteligencia artificial sobre el conjunto de prueba. Incluso el más modesto supera el 97 %, y el modelo subspace k-NN (en naranja) alcanza prácticamente el 100 %.

3.2 Segunda etapa: añadir un nuevo ingrediente y afinar el método.

En un trabajo posterior incorporamos una herramienta matemática adicional, la transformada de Hermite, especializada en captar detalles espaciales localizados como los bordes y las texturas finas de la lesión. La combinamos con las transformadas anteriores sobre los canales de color y usamos una red neuronal para clasificar. Este enfoque híbrido; que une lo mejor de la información global (las transformadas invariantes) con la información local (Hermite y textura), alcanzó una exactitud global cercana al 95 % sobre el conjunto de prueba.

Un hallazgo interesante de esta segunda etapa fue *dónde* acertaba y dónde dudaba el sistema (figura 2). Reconoció casi a la perfección la queratosis actínica, el dermatofibroma, las lesiones vasculares y el carcinoma de células escamosas. En cambio, mostró más dificultad para separar el melanoma del lunar común, precisamente las lesiones que también confunden al ojo humano por su gran parecido. Es un recordatorio honesto de que la herramienta refleja la dificultad real del problema, no la elimina por arte de magia.

Para dimensionar el desempeño de este método híbrido, la Tabla 3 resume sus principales métricas globales.

Tabla 3. Desempeño global del método híbrido (segunda etapa), promediado en las ocho lesiones tras 30 repeticiones.

Métrica	**Resultado**
Exactitud	95.33 %
Especificidad	97.33 %
Sensibilidad	81.24 %
Precisión	80.77 %
Puntaje F1 (balance precisión/sensibilidad)	80.82 %
Tasa de falsas alarmas	2.67 %

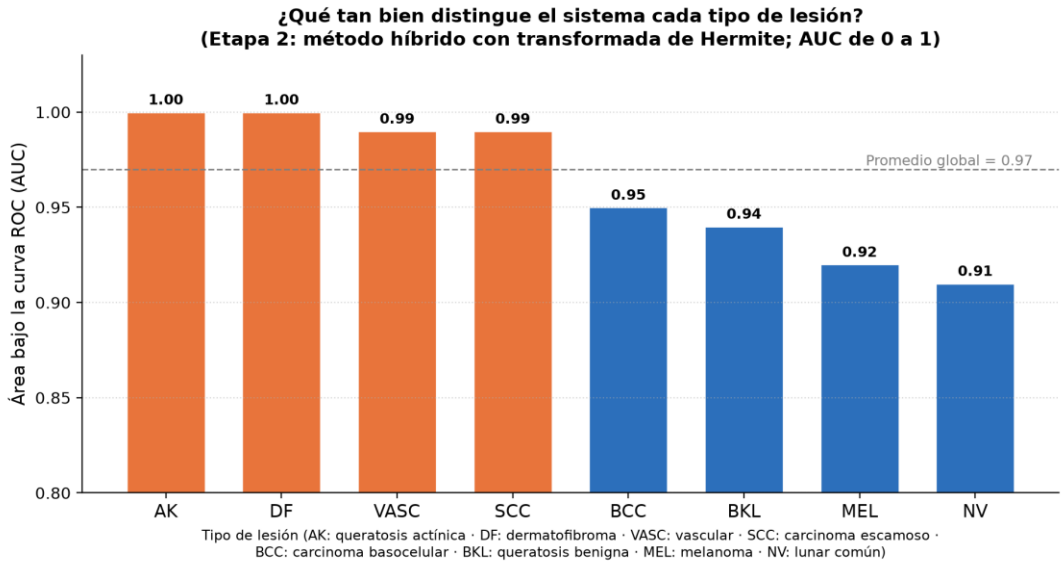


Figura 2. Capacidad del método híbrido para distinguir cada tipo de lesión, medida con el área bajo la curva ROC (AUC), donde 1.00 es la separación perfecta. Las lesiones en verde se identifican casi sin error; el melanoma (MEL) y el lunar común (NV), en naranja, son las más difíciles por su parecido visual.

Igual de importante es que el método destacó por su bajo número de falsas alarmas (una tasa de falsos positivos de apenas 2.67 %). En medicina esto es valioso: reduce diagnósticos positivos incorrectos que podrían generar angustia o tratamientos innecesarios al paciente.

Finalmente, comparamos nuestro método con varios modelos de referencia del estado del arte (redes neuronales profundas muy conocidas) sobre el mismo tipo de imágenes. Como muestra la figura 3, nuestro enfoque obtuvo la mayor exactitud del grupo.

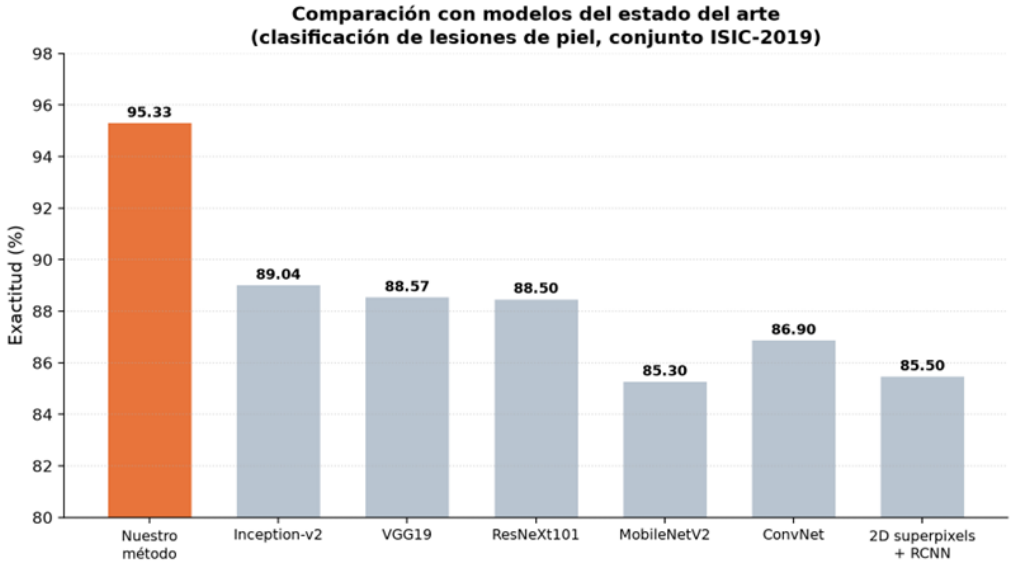


Figura 3. Comparación de la exactitud de nuestro método (naranja) frente a modelos del estado del arte para la clasificación de lesiones de piel. Además de la mayor exactitud, nuestro método aporta información que otros trabajos no reportan, como la especificidad (97.33 %) y la baja tasa de falsas alarmas.

4. Por qué importa: rapidez, sencillez y accesibilidad.

Quizá lo más prometedor no sean solo las cifras, sino cómo se obtuvieron. Todo el proceso se ejecutó en una computadora portátil común, sin equipo especializado. Los tiempos hablan por sí solos (Tabla 4): generar la firma de una imagen toma fracciones de segundo, y una vez entrenado, el sistema clasifica una lesión casi instantáneamente. Esto sugiere que la técnica podría llevarse a escenarios reales donde se necesite un análisis rápido y de bajo costo.

Tabla 4. Tiempos del método híbrido en una computadora portátil común (procesador Intel Core i5 de doble núcleo a 1.6 GHz, 8 GB de memoria).

Tarea	**Tiempo aproximado**
Generar la firma de una imagen (320 × 320)	0.30 segundos
Entrenar la red neuronal (una sola vez)	488 segundos (~8 minutos)
Clasificar una firma	0.000018 segundos

Frente a métodos más pesados basados en redes neuronales convolucionales, nuestro enfoque ofrece un equilibrio atractivo: firmas ligeras, estables ante giros y cambios de tamaño, y un costo de cómputo modesto, manteniendo al mismo tiempo una precisión competitiva con modelos del estado del arte.

Y hay algo más: la idea de convertir imágenes en firmas invariantes no es exclusiva de la piel. En principio podría aplicarse a otras tareas de imagen médica y más allá. Eso convierte a estas “huellas matemáticas” en una herramienta versátil con mucho camino por recorrer.

Conclusiones.

Enseñar a una computadora a reconocer lesiones de la piel no consiste necesariamente en mostrarle millones de fotografías y esperar que aprenda por fuerza bruta. Nuestro trabajo muestra que, con las matemáticas adecuadas, se puede traducir cada imagen a una firma compacta y estable que captura lo esencial de la lesión. Combinando transformadas integrales (Fourier, Mellin y Hilbert), la transformada de Hermite, descriptores de textura y el análisis por canales de color, logramos clasificar ocho tipos de lesiones con alta precisión y pocas falsas alarmas, usando recursos de cómputo modestos.

Estos resultados apuntan hacia herramientas de apoyo al diagnóstico dermatológico que sean no invasivas, rápidas y accesibles. No sustituyen al médico; la confusión entre melanoma y lunar común lo deja claro, pero sí pueden convertirse en un valioso segundo par de ojos que contribuya a la detección temprana del cáncer de piel y, con ello, al cuidado del paciente.

Créditos.

Estas investigaciones se realizaron en el Centro de Investigación Científica y de Educación Superior de Ensenada, B. C. (CICESE), con financiamiento institucional, así como el apoyo de la SECIHTI.

Referencias bibliográficas.

Guerra-Rosas, E.; López-Ávila, L. F.; Garza-Flores, E.; Vidales-Basurto, C. A.; Álvarez-Borrego, J. (2023). *Classification of Skin Lesion Images Using Artificial Intelligence Methodologies through Radial Fourier–Mellin and Hilbert Transform Signatures.* Applied Sciences, 13(20), 11425. https://doi.org/10.3390/app132011425.

López-Ávila, L. F.; Álvarez-Borrego, J. (2025). *Hybrid Transform-Based Feature Extraction for Skin Lesion Classification Using RGB and Grayscale Analysis*. Applied Sciences, 15(11), 5860. https://doi.org/10.3390/app15115860.

Información de los autores.



Luis Felipe López Ávila es Físico egresado de la Universidad Autónoma de Baja California (UABC). Obtuvo los grados de Maestría y Doctorado en Ciencias en el Centro de Investigación Científica y de Educación Superior de Ensenada (CICESE), donde desarrolló su formación en la línea de investigación de procesamiento de imágenes digitales. Actualmente realiza una estancia posdoctoral en el Centro de Investigación Científica y de Educación Superior de Ensenada, B. C. (CICESE) y es miembro del Sistema Nacional de Investigadoras e Investigadores (SNII) en el nivel candidato.



Esperanza Guerra Rosas obtuvo los grados de Ingeniería en Sistemas Computacionales y Maestría en Ciencias en Ingeniería Electrónica en el Instituto Tecnológico de Durango, México. Así como su Doctorado en Física en el Departamento de Investigación en Física en la Universidad de Sonora, México. Sus líneas de investigación incluyen el procesamiento de imágenes, el reconocimiento de patrones y algoritmos de Inteligencia Artificial. Actualmente realiza una estancia posdoctoral en el Centro de Investigación Científica y de Educación Superior de Ensenada, B.C., en la División de Física Aplicada. Pertenece al Sistema Nacional de Investigadoras e Investigadores (SNII nivel 1).



Josué Álvarez Borrego obtuvo el título de Licenciado en Oceanografía Física en la Facultad de Ciencias Marinas de la UABC (Ensenada, México), y los grados de Maestro y Doctor en Óptica en el Centro de Investigación Científica y de Educación Superior de Ensenada (CICESE, México). Actualmente es profesor Titular E en la División de Física Aplicada, Departamento de Óptica, del CICESE. Sus intereses de investigación incluyen el procesamiento de imágenes con aplicaciones en biología y medicina. Es miembro del Sistema Nacional de Investigadores (SNII, nivel 3), de la Academia Mexicana de Ciencias y de OPTICA (anteriormente OSA).



Esbanyely Garza Flores es egresado como Ingeniero en Electrónica de la Facultad de Ingeniería de la Universidad Autónoma de Baja California (UABC). Obtuvo el grado de Doctor en Ciencias en Óptica en el Centro de Investigación Científica y Educación Superior de Ensenada (CICESE) en 2018, y el de Maestro en Ciencias en Óptica en 2014. Ha realizado investigación en las áreas de óptica, reconocimiento de patrones, Ciencia de datos e inteligencia artificial. Produciendo artículos en revistas internacionales. Al momento se encuentra en una estancia posdoctoral en el grupo de Procesamiento de Imágenes del departamento de Óptica de la División de Física aplicada del CICESE, en investigación sobre la identificación de organismos marinos, como el fitoplancton, y de enfermedades, como el cáncer de piel, mediante el análisis de imágenes.