

Clasificación de cáncer de mama en imágenes termográficas mediante aprendizaje profundo y segmentación basada en Level Set

Breast Cancer Classification in Thermographic Images Using Deep Learning and Level Set-Based Segmentation

Pérez-Ibarra, G.¹; Tello-Mijares, S.²; Flores-García, F.³

Datos de Adscripción:

¹ Pérez Ibarra, Guillermo
Instituto Tecnológico de la Laguna. Torreón, Coahuila. México.
ROR ID: <https://ror.org/00xbw4a70>
m.gperezlalaguna.tecnm.mx
ORCID: <https://orcid.org/0009-0003-5437-0795>

² Tello Mijares, José de Jesús Santiago
Instituto Tecnológico de la Laguna. Torreón, Coahuila. México.
ROR ID: <https://ror.org/00xbw4a70>
jjstellom@lalaguna.tecnm.mx
ORCID: <https://orcid.org/0000-0002-2575-8251>

³ Flores García, Francisco
Instituto Tecnológico de la Laguna. Torreón, Coahuila. México.
ROR ID: <https://ror.org/00xbw4a70>
fgfloresg@correo.itlalaguna.edu.mx
ORCID: <https://orcid.org/0000-0002-6661-8191>

Resumen - El cáncer de mama constituye uno de los principales problemas de salud en la población femenina, por lo que la detección temprana resulta fundamental para mejorar el pronóstico clínico y aumentar las posibilidades de supervivencia. En este trabajo se presenta un método computacional para la clasificación automática de imágenes termográficas mamarias mediante técnicas de procesamiento digital de imágenes y aprendizaje profundo. El procedimiento propuesto emplea un proceso de segmentación basado en niveles de temperatura para identificar regiones térmicas de interés, las cuales son utilizadas como entrada de cinco modelos de redes neuronales convolucionales profundas. La evaluación experimental se realizó utilizando una base de datos compuesta por 1027 imágenes termográficas, correspondientes a 645 pacientes con cáncer de mama y 382 pacientes sin la enfermedad. Los resultados obtenidos muestran que el modelo VGG19 alcanzó el mejor desempeño de clasificación, con una sensibilidad del 100 %, una precisión del 100 % y una exactitud del 99.09 % utilizando un esquema de validación cruzada de dos particiones. Estos hallazgos demuestran el potencial del enfoque propuesto como herramienta de apoyo para la detección temprana del cáncer de mama y evidencian la efectividad del aprendizaje por transferencia en el análisis de imágenes médicas.

Palabras Clave - Aprendizaje por transferencia, Diagnóstico asistido por computadora, Imágenes infrarrojas, Segmentación térmica.

Abstract - Breast cancer remains one of the leading health problems affecting women worldwide, making early detection essential for improving clinical outcomes and

survival rates. This work presents a computational approach for the automatic classification of breast thermographic images using digital image processing techniques and deep learning models. The proposed method employs a temperature-level segmentation process to identify relevant thermal regions, which are subsequently used as inputs to five deep convolutional neural network models. Experimental evaluation was conducted using a database containing 1,027 thermographic images, including 645 patients diagnosed with breast cancer and 382 patients without the disease. The results indicate that the VGG19 model achieved the highest classification performance, reaching 100% sensitivity, 100% precision, and 99.09% accuracy under a two-fold cross-validation scheme. These findings demonstrate the potential of the proposed approach as a computer-aided tool for early breast cancer detection and highlight the effectiveness of transfer learning techniques for medical image analysis.

Keywords - Computer-aided diagnosis, Infrared imaging, Thermal segmentation, Transfer learning.

I. INTRODUCCIÓN

El cáncer que más afecta a las mujeres en el mundo es el cáncer de mama y, en 2020, la pandemia de la enfermedad por coronavirus 2019 (COVID-19) afectó el diagnóstico y tratamiento del cáncer (Siegel et al., 2020). Existen diferentes técnicas para llevar a cabo el diagnóstico de cáncer de mama, tales como la mamografía, la resonancia magnética (RM), el ultrasonido, la tomografía computarizada (TC) y las termografías (Cruz-Ramírez et al., 2013). La mamografía es un tipo de rayos X y es la técnica más común, con resultados precisos para la detección del cáncer de mama (Ibrahim et al., 2020), pero la TC tiene el potencial de detectar el cáncer de mama entre 8 y 10 años antes que la mamografía (Etehad Tavakol et al., 2013). Recientemente, para realizar la tarea de detección de cáncer de mama, ha aumentado el interés en el análisis y procesamiento de imágenes termográficas (Mahmoudzadeh et al., 2015). Estas técnicas son una herramienta potencial de tamizaje para la detección temprana del cáncer de mama (Silva et al., 2014), ya que ni la mamografía ni la RM de mama pueden identificar la diferencia entre un bulto canceroso y un quiste benigno (Parisky et al., 2003; Kennedy et al., 2009). El presente trabajo es una mejora en los tiempos de ejecución de (Tello-Mijares et al., 2019) y forma parte de un proyecto para desarrollar un sistema que capture automáticamente imágenes termográficas de mama utilizando un dispositivo mecánico y una

cámara infrarroja. El sistema selecciona imágenes que presentan una indicación suficiente de anomalías mamarias mediante un método rápido basado en *level set*. Este estudio tiene como objetivo determinar qué modelo de Red Neuronal Convolutiva Profunda (D-CNN) puede clasificar mejor las imágenes de termografía mamaria como con cáncer o sin cáncer (Figura 1).




Figura 1 Termografías mamarias: (a-b) con cáncer; (c-d) sin cáncer

La mamografía es uno de los métodos más utilizados para la detección de tumores de cáncer de mama; su efectividad puede ser afectada por la densidad del pecho del paciente, la edad, exponiendo al paciente a la radiación (Etehad Tavakol et al., 2013). Estas limitaciones han motivado la búsqueda de distintas alternativas no invasivas para la detección de cáncer de mama (Silva et al., 2014).

En este contexto, las redes neuronales artificiales y el aprendizaje supervisado han demostrado un alto potencial en la detección automática y clasificación de imágenes médicas (Francis et al., 2014; Milosevic et al., 2014). Modelos basados en redes neuronales convolucionales (CNN) pueden ser utilizados para la clasificación de imágenes termográficas de cáncer de mama, obteniendo mejoras significativas en métricas como, sensibilidad, precisión, especificidad comparado con métodos tradicionales (Rassiwala et al., 2014; Antonini et al., 2015).

Recientes investigaciones se han basado en el desarrollo de arquitecturas capaces no solo de clasificar, sino también de segmentar automáticamente regiones sospechosas (Gaber et al., 2015). En este caso, modelos como U-Net, Mask R-CNN y arquitecturas híbridas han sido adaptados al análisis de termografías de cáncer de mama, mostrando resultados prometedores en la identificación de regiones sospechosas asociadas a tumores de cáncer de mama (Madhu et al., 2016).

Una gran parte de los estudios se basan únicamente en una clasificación binaria (benigno/maligno), ignorando la segmentación de las regiones, que es esencial para aplicaciones clínicas más avanzadas (Esteve et al., 2021; Al Husaini et al., 2020). Por lo cual, es necesario continuar explorando redes neuronales convolucionales integrando la detección y segmentación de cáncer de mama en imágenes termográficas. Esta integración puede contribuir significativamente al desarrollo de sistemas de diagnóstico aún más robustos y accesibles (Patiño et al., 2024; Acosta et al., 2021).

Este artículo presenta un método con alta sensibilidad, precisión y exactitud para clasificar cáncer de mama en imágenes

termográficas (Figura 1). Los principales aportes son: el uso novedoso de un método de clasificación basado en niveles para el preprocesamiento de imágenes; el diseño de un modelo CNN; la evaluación de varias estrategias de clasificación; una revisión sistemática de trabajos relacionados; y la comparación de tiempos de ejecución del modelo principal.

Por lo tanto, el objetivo de este trabajo es desarrollar y evaluar un método computacional basado en segmentación por niveles de temperatura y modelos de aprendizaje profundo para la clasificación automática de imágenes termográficas de mama en pacientes con y sin cáncer, así como determinar el modelo de red neuronal convolutiva profunda que presenta el mejor desempeño en la tarea de clasificación.

El trabajo se organiza de la siguiente manera: la Sección II describe el procedimiento del método propuesto (Figura 2); la Sección III presenta los resultados usando los modelos D-CNN mediante un esquema de validación cruzada de dos particiones; finalmente, en la Sección IV se discuten los resultados y se presentan las conclusiones.

II. PARTE TÉCNICA DEL ARTÍCULO

La Figura 2 muestra el método propuesto de clasificación basada en *Level Set* para imágenes termográficas de mama, impulsado por redes neuronales convolucionales profundas (D CNN), con el fin de clasificar los casos con cáncer o sin cáncer. El procedimiento se detalla en las siguientes subsecciones. Inicialmente se utilizaron 1,034 imágenes termográficas de mama proporcionadas por (Silva et al., 2014).




Figura 2 Método descriptor para la clasificación de termografías mamarias

Primero, se seleccionaron las temperaturas de las áreas de interés mediante un método basado en *level set*. Posteriormente, para aprendizaje por transferencia, se consideraron cinco modelos D CNN ampliamente conocidos: AlexNet, EfficientNetB0, GoogleNet, VGG16 y VGG19. Estas redes fueron preentrenadas con un gran conjunto de datos de clasificación de imágenes y adaptadas a la tarea objetivo reemplazando las capas finales de la arquitectura para una clasificación binaria. Los modelos se evaluaron en dos tareas de predicción: clasificación en Cáncer de Mama Termográfico (BC) o Mama Termográfica Sin Cáncer (BNC).

El estudio se desarrolló bajo un enfoque experimental de clasificación supervisada. Inicialmente, las imágenes termográficas fueron sometidas a una etapa de preprocesamiento basada en segmentación por niveles de

temperatura para identificar regiones térmicas de interés. Posteriormente, las imágenes procesadas fueron utilizadas como entrada para los modelos de aprendizaje profundo, los cuales fueron adaptados mediante aprendizaje por transferencia para realizar una clasificación binaria entre pacientes con cáncer de mama y pacientes sin cáncer. Finalmente, el desempeño de los modelos fue evaluado mediante un esquema de validación cruzada de dos particiones utilizando métricas de clasificación ampliamente empleadas en el análisis de imágenes médicas.

2.1. Preprocesamiento de las áreas de interés térmicas

Esta etapa consiste en un preprocesamiento novedoso de la región de interés basado en las temperaturas principales de las áreas de interés en mamas normales y en aquellas que presentan anomalías cancerígenas, empleando un método inicial de segmentación basado en level set. El objetivo es aislar o segmentar las regiones de la mama que puedan corresponder a tejido normal o a anomalías asociadas al cáncer, para posteriormente someter una parte representativa a clasificación mediante los modelos D CNN.

El cáncer de mama ocurre cuando las células comienzan a crecer de manera descontrolada e invaden tejidos cercanos o se diseminan por el cuerpo (Ng, 2007). El desarrollo del cáncer tiende a incrementar la temperatura en la superficie de la mama. Por esta razón, se propuso separar la imagen termográfica en diez niveles de umbral utilizando la componente H normalizada del modelo de color HSI.

En el modelo HSI, los colores se distinguen por H (tono), S (saturación) e I (intensidad) (Alvarado-Robles et al., 2017). H está relacionado con la longitud de onda dominante. Por ejemplo, cuando $H = 0^\circ$, el color es rojo; cuando $H = 60^\circ$, es amarillo. Según la verdad de terreno, los colores rojos en la mama indican anomalías, mientras que las temperaturas normales se representan en tonos amarillos y verdes.

Primero se obtuvo la imagen H normalizada en el rango $[0, 1]$ a partir de la imagen termográfica. Luego, la imagen H se dividió en diez niveles diferentes. De estos, se seleccionaron los niveles 2, 9 y 10, que contienen los colores de interés para distinguir entre imágenes termográficas con y sin cáncer.

El resultado de este recorte genera imágenes de entrada para los modelos D CNN, compuestas únicamente por regiones conectadas que cumplen estas restricciones térmicas relevantes. Esta fase está diseñada para maximizar la sensibilidad (recall) y evitar falsos negativos, aspecto crítico en imágenes médicas. Las fases posteriores buscan maximizar la precisión, reduciendo falsos positivos mediante aprendizaje profundo.

2.2. Redes Neuronales Convolucionales Profundas

Se propone un preprocesamiento eficiente de las áreas térmicas de interés para alimentar los modelos D CNN, reemplazando sus capas finales mediante aprendizaje por transferencia (Figura 2). Las CNN fueron propuestas inicialmente por LeCun et al. (1998) y combinan tres ideas arquitectónicas principales: campos receptivos locales, pesos compartidos y submuestreo espacial o temporal.

Una CNN se compone básicamente de tres tipos de capas: capas de convolución espacial, capas de submuestreo y capas totalmente conectadas.

Se utilizaron cinco modelos D CNN diseñados para procesar imágenes tridimensionales: (AlexNet, EfficientNetB0, GoogleNet, VGG16 y VGG19. La motivación radica en que las CNN ofrecen ventajas jerárquicas y robustez frente a variaciones en la

posición, el tamaño, la iluminación, la rotación, el ruido y la distorsión.

Estos modelos han sido aplicados previamente en reconocimiento de escritura, detección y reconocimiento facial. En este trabajo se modificaron las últimas capas de cada red para lograr una clasificación binaria. El método propuesto demostró ser más robusto y eficiente que enfoques tradicionales basados únicamente en características clásicas, además de aprovechar imágenes preprocesadas en 3D en lugar de imágenes en escala de grises.

Las principales contribuciones incluyen: generación de imágenes de entrada que capturan información térmica relevante, construcción de un conjunto de datos representativo para validación cruzada 2-fold, y evaluación comparativa de múltiples arquitecturas D CNN para el problema de clasificación.

2.3. Reemplazo de las capas finales mediante un enfoque de Transfer Learning

Para adaptar estas redes preentrenadas a la tarea de diferenciar entre imágenes termográficas de mama, se reemplazan todas las capas posteriores al último bloque convolucional (es decir, las capas totalmente conectadas, softmax y la salida de clasificación, Figura 2) por nuevas capas con el tamaño adecuado (imágenes termográficas de mama con cáncer y sin cáncer; 2 clases). Después, las redes modificadas se ajustan (fine-tuning) utilizando ejemplos de entrenamiento de la nueva tarea.

Las arquitecturas empleadas corresponden a modelos de redes neuronales convolucionales profundas preentrenados sobre el conjunto de datos ImageNet. Para adaptarlas a la tarea de clasificación de imágenes termográficas mamarias, las capas finales de clasificación fueron reemplazadas por nuevas capas de salida correspondientes a las dos categorías de estudio (cáncer de mama y sin cáncer). Posteriormente, cada modelo fue ajustado mediante aprendizaje por transferencia y evaluado bajo las mismas condiciones experimentales con el propósito de realizar una comparación objetiva de su desempeño. Para evaluar el desempeño de los modelos se empleó un esquema de validación cruzada de dos particiones (2-fold cross-validation). El conjunto de datos se dividió en dos subconjuntos de tamaño similar; en la primera iteración, uno de ellos fue utilizado para entrenamiento y el otro para prueba. Posteriormente, los subconjuntos intercambiaron sus funciones y los resultados finales se obtuvieron mediante el promedio de ambas iteraciones.

III. RESULTADOS Y DISCUSIÓN

3.1. Conjunto de datos

El conjunto de datos utilizado corresponde a la Database for Mastology Research (DMR), desarrollada por Silva et al. (2014), y está compuesto por 1027 imágenes termográficas de mama en formato RGB y JPEG, con un tamaño de $160 \times 120 \times 3$ píxeles y una resolución de 72×72 ppp. Del total de imágenes, 645 corresponden a pacientes con cáncer de mama (BC) y 382 a pacientes sin evidencia de la enfermedad (BNC). Todas las imágenes disponibles en la base de datos fueron consideradas en el estudio, sin aplicar criterios de exclusión, debido a que cada una cuenta con un diagnóstico previamente establecido,

permitiendo la evaluación de los modelos bajo un esquema de clasificación supervisada. La Figura 1 muestra algunos ejemplos representativos del conjunto de datos.

3.2. Indicadores de calidad para la clasificación de termografías

Se presentan distintos indicadores de calidad para evaluar cuantitativamente los resultados de la clasificación mamaria y el desempeño de los modelos D CNN: AlexNet, EfficientNetB0, GoogleNet, VGG16 y VGG19. Los indicadores de calidad se dividen en internos y externos.

Los indicadores externos evalúan los resultados finales de clasificación y permiten la comparación con otros trabajos. Los indicadores internos se utilizan para evaluar el comportamiento interno de los cinco modelos D CNN propuestos, donde la Tabla 1 y Tabla 2 resumen todos los resultados cuantitativos.

Tabla 1

Resultados de los indicadores internos y externos de los modelos usados

Modelo D CNN	Indicadores externos			Indicadores internos		
	TPR	PPV	F1	SPC	NPV	FDR
AlexNet	100	100	99.8	99	100	0.8
EfficientNetb0	100	100	99.7	99	99	0.5
GoogleNet	100	100	99.6	99	99	0.8
Vgg16	100	100	99.8	99	100	0.8
Vgg19	100	100	99.9	--	100	0.3

ACC—precisión; D CNN—red neuronal convolucional profunda; F1—puntuación F1; FDR—tasa de falsos descubrimientos; FPR—tasa de falsos positivos o de caída; HM—media armónica; VPN—valor predictivo negativo; VPP—precisión o valor predictivo positivo; SPC—especificidad o tasa de verdaderos negativos; TPR—sensibilidad, recuperación o tasa de verdaderos positivos.

Tabla 2

Matriz de confusión resultante de los modelos usados.

Matriz de Confusión			
AlexNet			
TP	645	FN	0
FP	3	TN	379
EfficientNetb0			
TP	643	FN	2
FP	2	TN	380
GoogleNet			
TP	643	FN	2
FP	3	TN	380
Vgg16			
TP	645	FN	9
FP	3	TN	379
Vgg19			
TP	645	FN	0
FP	1	TN	381

TP – Verdaderos Positivos; FP – Falsos Positivos; FN – Falsos Negativos; TN – Verdaderos Negativos

Para los indicadores externos, se define la detección positiva P como el número de imágenes termográficas de mama con cáncer en el conjunto de datos; los verdaderos positivos como TP , falsos positivos como FP , y falsos negativos como FN .

La sensibilidad, también conocida como recall o tasa de verdaderos positivos, se define como se muestra en (1).

$$TPR = TP/P \quad (1)$$

La precisión o valor predictivo positivo es definida como en (2).

$$PPV = TP/(TP + FP) \quad (2)$$

La tasa de falsos descubrimientos se define como se muestra en (3).

$$FDR = FP/(FP + TP) \quad (3)$$

El puntaje F1, correspondiente a la media armónica entre TPR y PPV se define como se muestra en (4).

$$F1 = 2TP/(2TP + FP + FN) \quad (4)$$

La media armónica también puede expresarse como se muestra en (5)

$$HM = 2 * TPR * PPV/(TPR + PPV) \quad (5)$$

Los modelos D-CNN clasifican las regiones de interés térmicas de la mama en con cáncer o sin cáncer. Se evaluó el desempeño mediante indicadores internos de calidad. Se define N como el número de imágenes termográficas de mama sin cáncer obtenidas tras aplicar el método propuesto al conjunto completo, y TN como el número de verdaderos negativos. La especificidad o tasa de verdaderos negativos se define como se muestra en (6).

$$SPC = TN/N \quad (6)$$

El valor predictivo negativo se define como se muestra en (7).

$$NPV = TN/(TN + FN) \quad (7)$$

La exactitud se define como se muestra en (8).

$$ACC = (TP + TN)/(TP + FP + TN + FN) \quad (8)$$

La tasa de falsos positivos (*fall-out*) se define como se muestra en (9).

$$FPR = FP/N \quad (9)$$

En este trabajo se exploraron cinco modelos D CNN representativos (AlexNet, EfficientNetB0, GoogleNet, VGG16 y VGG19.), aplicando el experimento de clasificación más difícil y realista mediante un esquema de validación cruzada de 2 pliegues (2-fold cross-validation) para entrenamiento y prueba. AlexNet, VGG16 y VGG19 lograron los mejores resultados bajo este esquema, donde el conjunto de datos se divide en dos partes iguales: una parte se usa para entrenamiento y la otra para prueba; posteriormente se intercambian. Esto demuestra las ventajas de AlexNet, VGG16 y VGG19 para la clasificación de imágenes termográficas de mama frente a otros clasificadores del estado del arte.

Se demostró que el clasificador D CNN obtuvo resultados más expresivos en el diagnóstico de anomalías mamarias cuando se realiza un preprocesamiento en color. Nuestro estudio arroja luz sobre que el enfoque D CNN es válido con base en nuestros resultados de clasificación: TPR=100%, PPV=100% y ACC=99.9 para un conjunto de datos que contiene 1027 imágenes mamarias (645 con cáncer y 374 sin) usando la validación

cruzada de 2 folds más difícil, en comparación con otros estudios similares de “estado del arte” para métodos de clasificación de cáncer de mama como se muestra en la Tabla 3.

Tabla 3

Comparación con estudios presentes en el estado del arte de clasificación de cáncer de mama.

Ref	Data Set	fold	Indicadores Externos			Indicadores Internos	
			TPR	PPV	F1	SPC	ACC
Prop Vgg19	1027	s=2	100	100	99.9	100	99.9
Etehad							
Tavakol et al. (2013)	32	s=10					95
Cruz-Ramirez et al. (2013)	98	s=10	82			37	71.88
Ng (2007)	54	LOF					92
Schaefer et al. (2009)	146	s=10	80			80	80
Etehad							
Tavakol et al. (2010)	15	LOF					90
Araújo et al. (2014)	50	LOF	85.7			86.5	
Francis et al. (2014)	36	LOF	83.3			83.3	83.3
Milosevic et al. (2014)	40	s=5	78.6	100		100	92.5
Rassiwala et al. (2014)	1008	LOF	97.6	83.7		99.1	
Antonini et al. (2015)	51	LOF	100				
Gaber et al. (2015)	63	LOF					100
Mejía et al. (2015)	18	LOF					94.44
Madhu et al. (2016)	265	s=2	100			99	
Rastghalam y Pourghassem (2016)	65	LOF	87.5	92		88.5	87
Celaya-Padilla et al. (2018)	152	s=10					75.25
Vasconcelos et al. (2018)	175	s=3	94.73			92.1	93.42
Mambou et al. (2018)	1062	0.8/0.2					100
de Freitas Oliveira Baffa y Lattari (2018)	219	s=10					98
Roslidar et al. (2019)	2966	0.8/0.2	100	100	100		100
Torres-Galvan et al. (2019)	173	0.7/0.3	100	100		82.4	91.18
Zuluaga-Gomez et al. (2020)	1120	0.7/0.3	91		92	94	92
Fernández-Ovies et al. (2019)	1000	0.8/0.2					100
Karami et al. (2025)	218	s=10	90	93	90	93	90
Escobar et al. (2021)	120	s=10	87.5	75.6	78	46.3	72.2

Montero-Cadena y Silva-Acosta (2025)	LOF	s=10	98.17	98.2			98.17
Castillo et al. (2025)	565	s=5	73	97	85	76	76
Celis et al. (2022)	2780	s=10	87.03	97.7	92		97.73
Mercedes y Bogotá (2021)	500	s=10	73	73		67	73
Patiño et al. (2024)	6493	0.8	99.3		99.3		99.4
Acosta et al. (2021)	7909	s=10	90.16	88.7	89.4	93.1	93.06
Sosa (2021)	500	s=10	90	95	92.5	90	90
Loaiza y Restrepo (2021)	40	s=5		65.7			65.7
Boubchir et al. (2023)	2057	s=10	91.44	97.1		85.9	97.13
Li et al. (2024)	780	s=10	94.8	96.2	91.9		96.2
Xu et al. (2023)	2157	s=10	95.7	97.1	91.4	97.5	97.13
Zhang et al. (2024)	1200	s=10	92.6	94.3	93	95.8	94.3
Chen et al. (2023)	800	s=10	87.3	89.9	88.5		89.91
Zhao et al. (2023)	780	s=10	95.8	97	92.1	97.9	97
Wang et al. (2023)	1000	s=10	94.2	95.6	95		95.6
Ahmed et al. (2023)	780	s=10	90.5	96.4	90.5	84.2	96.4
Liu et al. (2024)	749	s=10	92.5	93.7	93	95.1	93.7
Zhang et al. (2022)	2600	s=10	91.2			85.9	95.8
Shilaskar et al. (2025)	LOF	s=10	90	98	94	98	98
El-Banby et al. (2024)	1200	s=10	94.5		91.2	97.9	96.8
Alzahrani et al. (2025)	500	s=10	94.1	95	95		95.4

ACC–precisión; D CNN–red neuronal convolucional profunda; F1–puntuación F1; FDR–tasa de falsos descubrimientos; FPR–tasa de falsos positivos o de caída; HM–media armónica; LOF–falta de información; NPV–valor predictivo negativo; PPV–precisión o valor predictivo positivo; SPC–especificidad o tasa de verdaderos negativos; TPR–sensibilidad, recuperación o tasa de verdaderos positivos.

IV. CONCLUSIONES

La identificación del cáncer de mama en imágenes termográficas mamarias es generalmente aceptada como un requisito previo para el diagnóstico. Presentamos un estudio con redes neuronales convolucionales profundas (D-CNN) para clasificar imágenes mamarias, obteniendo resultados de 100% de sensibilidad (recall), 100% de precisión y 99.9% de exactitud en la situación más exigente de entrenamiento-prueba, mediante validación cruzada de 2 particiones.

Por consiguiente, se cumple el objetivo del estudio al determinar que el modelo VGG19 presenta el mejor desempeño para la

clasificación de imágenes termográficas de mama, demostrando el potencial del método propuesto para el desarrollo de sistemas de apoyo al diagnóstico temprano del cáncer de mama.

En este trabajo analizamos imágenes termográficas de mama utilizando un método novedoso que selecciona áreas de interés de temperatura y, posteriormente, regiones térmicas de interés de la mama para alimentar un modelo D-CNN con el fin de determinar la diferencia entre casos con cáncer y sin cáncer; además, se generó un conjunto de datos de referencia (ground truth) representativo elaborado por médicos especialistas y se evaluaron diversas estrategias de clasificación para abordar este problema. También realizamos un análisis exhaustivo de los trabajos reportados en el tema y discutimos nuestros resultados a la luz de dichos estudios. Este análisis valida razonablemente la novedad y la calidad de nuestros logros, en ausencia de un marco completamente justo que permita comparar objetivamente los resultados.

Proponemos investigar y desarrollar modelos basados en D-CNN que utilicen imágenes termográficas mamarias para clasificar casos con y sin cáncer. Nuestros resultados muestran que el uso de imágenes preprocesadas mediante Level Set produce la mayor exactitud en la clasificación. Específicamente, el modelo Vgg19 es el mejor modelo D-CNN para clasificar imágenes termográficas mamarias. Estudios futuros podrían aportar información adicional sobre las imágenes termográficas de mama para evaluar la progresión del cáncer utilizando estos modelos D-CNN.

V. AGRADECIMIENTOS

Este estudio fue apoyado parcialmente por la Subvención Interna del Instituto Tecnológico de la Laguna. Los autores declaran no tener conflicto de interés.

VI. REFERENCIAS

- Siegel, R. L., Miller, K. D. y Jemal, A. (2020). Cancer statistics, 2020. *CA: Cancer Journal for Clinicians*, 70(3), 145-164. <https://doi.org/10.3322/caac.21601>
- Cruz-Ramirez, N., Efrén, M. M. y María Yaneli, A. A. (2013). Evaluation of the diagnostic power of thermography in breast cancer using bayesian network classifiers. *Computational and Mathematical Methods in Medicine*, 2013, 264246. <https://doi.org/10.1155/2013/264246>
- Ibrahim, A., Mohammed, S., Ali, H. A. y Hussein, S. E. (2020). Breast cancer segmentation from thermal images based on chaotic salp swarm algorithm. *IEEE Access*, 8, 122121-122134. <https://doi.org/10.1109/ACCESS.2020.3007336>
- Etehad Tavakol, M., Chandran, V., Ng, E. Y. K. y Kafieh, R. (2013). Breast cancer detection from thermal images using bispectral invariant features. *International Journal of Thermal Sciences*, 69, 21-36. <https://doi.org/10.1016/j.ijthermalsci.2013.03.001>
- Mahmoudzadeh, E., Montazeri, M. A., Zekri, M. y Sadri, S. (2015). Extended hidden Markov model for optimized segmentation of breast thermography images. *Infrared Physics & Technology*, 72, 19-28. <https://doi.org/10.1016/j.infrared.2015.06.012>
- Silva, L. F., Saade, D. C. M., Sequeiros, G. O., Silva, A. C., Paiva, A. C., Bravo, R. S. y Conci, A. (2014). A new database for breast research with infrared image. *Journal of Medical Imaging and Health Informatics*, 4(1), 92-100. <https://doi.org/10.1166/jmihi.2014.1226>
- Parisky, Y. R., Sardi, A., Hamm, R., Hughes, K., Esserman, L., Rust, S. y Callahan, K. (2003). Efficacy of computerized infrared imaging analysis to evaluate mammographically suspicious lesions. *American Journal of Roentgenology*, 180(1), 263-269. <https://doi.org/10.2214/ajr.180.1.1800263>
- Kennedy, D., Lee, T. y Seely, D. (2009). A comparative review of thermography as a breast screening technique. *Integrative Cancer Therapies*, 8, 9-16. <https://doi.org/10.1177/1534735408326171>
- Tello-Mijares, S., Woo, F. y Flores, F. (2019). Breast cancer identification via thermography image segmentation with a gradient vector flow and a convolutional neural network. *Journal of Healthcare Engineering*, 2019, Article 9807619. <https://doi.org/10.1155/2019/9807619>
- Ng, E. Y. K. (2007). Detection and differentiation of breast cancer using neural classifiers with first warning thermal sensors. *Information Sciences*, 177(20), 4526-4538. <https://doi.org/10.1016/j.ins.2007.03.027>
- Schaefer, G., Závisek, M. y Nakashima, T. (2009). Thermography based breast cancer analysis using statistical features and fuzzy classification. *Pattern Recognition*, 42(6), 1133-1137. <https://doi.org/10.1016/j.patcog.2008.08.007>
- Etehad Tavakol, M., Lucas, C., Sadri, S. y Ng, E. Y. K. (2010). Analysis of breast thermography using fractal dimension to establish possible difference between malignant and benign patterns. *Journal of Healthcare Engineering*, 1(1), 27-43. <https://doi.org/10.1260/2040-2295.1.1.27>
- Araújo, M. C., Lima, R. C. y De Souza, R. M. (2014). Interval symbolic feature extraction for thermography breast cancer detection. *Expert Systems with Applications*, 41(15), 6728-6737. <https://doi.org/10.1016/j.eswa.2014.04.027>
- Francis, S. V., Sasikala, M., Bharathi, G. B. y Jaipurkar, S. D. (2014). Breast cancer detection in rotational thermography images using texture features. *Infrared Physics & Technology*, 67, 490-496. <https://doi.org/10.1016/j.infrared.2014.08.019>
- Milosevic, M., Jankovic, D. y Peulic, A. (2014). Thermography based breast cancer detection using texture features and minimum variance quantization. *EXCLI Journal*, 13, 1204-1215.
- Rassiwal, M., Mathur, P., Mathur, R., Farid, K., Shukla, S., Gupta, P. K. y Jain, B. (2014). Evaluation of digital infra-red thermal imaging as an adjunctive screening method for breast carcinoma: A pilot study. *International Journal of Surgery*, 12(12), 1439-1443. <https://doi.org/10.1016/j.ijsu.2014.11.027>
- Antonini, S., Kolarić, D., Herceg, Ž., Kuliš, T., Ferenčič, Ž., Katančič, J. y Banič, M. (2015). Thermographic visualization of multicentric breast carcinoma. *Proceedings of the IEEE 57th International Symposium ELMAR*, 13-16. <https://doi.org/10.1109/ELMAR.2015.7334484>
- Gaber, T., Ismail, G., Anter, A., Soliman, M., Ali, M., Semary, N. y Snasel, V. (2015). Thermogram breast cancer prediction approach based on neutrosophic sets and fuzzy c-means algorithm. *Proceedings of the IEEE 37th Annual International Conference of*

- the Engineering in Medicine and Biology Society (EMBC), 4254-4257. <https://doi.org/10.1109/EMBC.2015.7319334>
- Mejía, T. M., Pérez, M. G., Andaluz, V. H. y Conci, A. (2015). Automatic segmentation and analysis of thermograms using texture descriptors for breast cancer detection. *Proceedings of the IEEE Asia-Pacific Conference on Computer Aided System Engineering (APCASE)*, 24-29. <https://doi.org/10.1109/APCASE.2015.12>
- Madhu, H., Kakileti, S. T., Venkataramani, K. y Jabbireddy, S. (2016). Extraction of medically interpretable features for classification of malignancy in breast thermography. *Proceedings of the IEEE 38th Annual International Conference of the Engineering in Medicine and Biology Society (EMBC)*, 1062-1065. <https://doi.org/10.1109/EMBC.2016.7590886>
- Rastghalam, R. y Pourghassem, H. (2016). Breast cancer detection using MRF-based probable texture feature and decision-level fusion-based classification using HMM on thermography images. *Pattern Recognition*, 51, 176-186. <https://doi.org/10.1016/j.patcog.2015.09.009>
- Celaya-Padilla, J. M., Guzmán-Valdivia, C. H., Galván-Tejada, C. E., Galván-Tejada, J. I., Gamboa-Rosales, H. y Luna-García, H. (2018). Contralateral asymmetry for breast cancer detection: A CADx approach. *Biocybernetics and Biomedical Engineering*, 38(1), 115-125. <https://doi.org/10.1016/j.bbe.2017.10.005>
- Vasconcelos, J. H., dos Santos, W. P. y Lima, R. C. F. (2018). Analysis of methods of classification of breast thermographic images to determine their viability in the early breast cancer detection. *IEEE Latin America Transactions*, 16(6), 1631-1637. <https://doi.org/10.1109/TLA.2018.8444159>
- Esteva, A., Chou, K., Yeung, S., Naik, N., Madani, A., Mottaghi, A., Liu, Y., Topol, E., Dean, J. y Socher, R. (2021). Deep learning-enabled medical computer vision. *NPJ Digital Medicine*, 4, 5. <https://doi.org/10.1038/s41746-020-00376-2>
- Al Husaini, M. A. S., Habaebi, M. H., Hameed, S. A., Islam, M. R. y Gunawan, T. S. (2020). A systematic review of breast cancer detection using thermography and neural networks. *IEEE Access*, 8, 208922-208937. <https://doi.org/10.1109/ACCESS.2020.3038817>
- Mambou, S., Maresova, P., Krejcar, O., Selamat, A. y Kuca, K. (2018). Breast cancer detection using infrared thermal imaging and a deep learning model. *Sensors*, 18(9), 2799. <https://doi.org/10.3390/s18092799>
- de Freitas Oliveira Baffa, M. y Lattari, L. G. (2018). Convolutional neural networks for static and dynamic breast infrared imaging classification. *Proceedings of the 31st SIBGRAPI Conference on Graphics, Patterns and Images*, 174-181. <https://doi.org/10.1109/SIBGRAPI.2018.00029>
- Roslidar, R., Saddami, K., Arnia, F., Syukri, M. y Munadi, K. (2019). A study of fine-tuning CNN models based on thermal imaging for breast cancer classification. *Proceedings of the IEEE International Conference on Cybernetics and Computational Intelligence*, 77-81. <https://doi.org/10.1109/CYBERNETICSCOM.2019.8875661>
- Torres-Galvan, J. C., Guevara, E. y Gonzalez, F. J. (2019). Comparison of deep learning architectures for pre-screening of breast cancer thermograms. *Proceedings of Photonics North*, 1-2. <https://doi.org/10.1109/PN.2019.8819587>
- Zuluaga-Gomez, J., Al Masry, Z., Benaggonne, K., Meraghni, S. y Zerhouni, N. (2020). A CNN-based methodology for breast cancer diagnosis using thermal images. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 9(2), 131-145. <https://doi.org/10.1080/21681163.2020.1824685>
- Fernández-Ovies, F. J., Santiago Alférez-Baquero, E., Andrés-Galiana, E. J. D., Cernea, A., Fernández-Muñiz, Z. y Fernández-Martínez, J. L. (2019). Detection of breast cancer using infrared thermography and deep neural networks. *International Work-Conference on Bioinformatics and Biomedical Engineering*, 514-523. https://doi.org/10.1007/978-3-030-17935-9_46
- Alvarado-Robles, G., Terol-Villalobos, I. R., Garduño-Ramon, M. A. y Morales-Hernandez, L. A. (2017). Segmentation of green areas using bivariate histograms based in hue-saturation type color spaces. *International Conference on Image Analysis and Processing*, 277-287. https://doi.org/10.1007/978-3-319-68548-9_26
- LeCun, Y., Bottou, L., Bengio, Y. y Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324. <https://doi.org/10.1109/5.726791>
- Karami, A. et al. (2025). Development of a predictive model for breast cancer detection using radiomics-based mammography and machine learning. *Egyptian Journal of Radiology and Nuclear Medicine*, 56, 68. <https://doi.org/10.1186/s43055-025-01456-3>
- Escobar, M. de la L., De la Rosa, J. I., Galván-Tejada, C. E., Galván-Tejada, J. I., Gamboa-Rosales, H. y Celaya-Padilla, J. M. (2021). Machine learning for breast cancer detection. *Computación y Sistemas*, 25(5).
- Montero-Cadena, F. J. y Silva-Acosta, J. D. (2025). Use of artificial intelligence in breast cancer diagnosis. *Ciencia Latina Revista Científica Multidisciplinar*, 9(1). https://doi.org/10.37811/cl_rcm.v9i1.12289
- Castillo, C., Pavia, G. y García, D. (2025). Artificial intelligence model for breast cancer diagnosis: A neural network-based approach. *Universidad del Norte*.
- Celis, E., Sarmiento, O. y Calderón, B. (2022). Development of a convolutional neural network for breast cancer detection through mammography image classification. *Revista Colombiana de Tecnologías de Avanzada*, 2(40).
- Mercedes, M. y Bogotá, S. C. (2021). Characterization of breast lesions through digital mammography image processing. *EIEI ACOFI Papers*.
- Patiño, M., Pérez, E. y S. S. (2024). Early breast cancer detection: Mammogram classification using a deep learning model. *Revista Ibérica de Sistemas e Tecnologías de Informação (RISTI)*, 55, 21-30. <https://doi.org/10.17013/risti.55.21-30>
- Acosta, L., Macías, M. y Ramírez, A. (2021). Classification of breast cancer histology images using a lightweight convolutional neural network. *Revista Electrónica de Ingeniería del IT Chihuahua*.
- Sosa, M. (2021). Digital mammography image processing for the characterization of breast lesions. *Repositorio Escuela Colombiana de Ingeniería Julio Garavito*.
- Loaiza, L. S. y Restrepo, H. (2021). Automatic segmentation of breast thermal images to support cancer detection. *Revista Sistemas & Telemática*, 13(34). <https://doi.org/10.18046/syt.v13i34.4731>
- Boubchir, L., Wang, A., Mdletshe, S., Williamson, B. y Xu, G. (2023). Fast segmentation and diagnosis of breast tumor ultrasound

- images at sonographer level using deep learning. *Frontiers in Oncology*. <https://doi.org/10.3389/fonc.2023.1165415>
- Li, Y. et al. (2024). Automatic joint segmentation and classification of breast ultrasound images using multitask learning with object context attention (MTL-OCA). *Frontiers in Oncology*. <https://doi.org/10.3389/fonc.2024.1402216>
- Xu, H. et al. (2023). Efficient deep learning strategy for accurate and automatic segmentation of breast tumors in ultrasound (U2NET-Lite). *Frontiers in Oncology*. <https://doi.org/10.3389/fonc.2023.1185381>
- Zhang, L. et al. (2024). Segmentation-based classification of mammograms using deep learning. *BMC Medical Imaging*. <https://doi.org/10.1186/s12880-024-01085-6>
- Chen, J. et al. (2023). Modified LeNet convolutional network for breast cancer diagnosis in ultrasound images. *Frontiers in Oncology*. <https://doi.org/10.3389/fonc.2023.1186023>
- Zhao, Q. et al. (2023). Multitask learning for tumor segmentation and classification in breast ultrasound images. *Frontiers in Oncology*. <https://doi.org/10.3389/fonc.2023.1207474>
- Ahmed, K. et al. (2023). Automatic breast tumor segmentation in ultrasound using optimized hybrid U-Net and shallow CNN for classification. *Computer Methods and Programs in Biomedicine*. <https://doi.org/10.1016/j.cmpb.2023.107921>
- Liu, X. et al. (2024). Deep learning for describing breast ultrasound images using BI-RADS. *Journal of Digital Imaging*. <https://doi.org/10.1007/s10278-023-00980-2>
- Zhang, Y. et al. (2022). Dual convolutional neural networks for breast mass segmentation and diagnosis in mammography (DualCoreNet). *arXiv preprint, arXiv:2204.01772*.
- Alzahrani, R. M. et al. (2025). Early detection of breast cancer using infrared thermography and convolutional neural networks. *Scientific Reports*, 15. <https://doi.org/10.1038/s41598-025-85841-y>
- El-Banby, G. M., Salem, N. S., Tafweek, E. A. y Abd El-Azziz, E. N. (2024). Automated anomaly detection in mammograms using a deep U-Net framework. *Computer Methods and Programs in Biomedicine*. <https://doi.org/10.1016/j.cmpb.2024.107993>
- Shilaskar, S., Bhatlawande, S., Talewar, M., Goud, S., Tak, S., Kurian, S. y Solanke, A. (2025). Classification and segmentation of breast tumors in ultrasound images using VGG-16 and U-Net. *Biomedical and Pharmacology Journal*, 18(1). <https://doi.org/10.13005/bpj/2740>
- Wang, R. et al. (2023). Multi-feature fusion and multitask model for breast tumor ultrasound images (MFFMT). *Current Oncology*, 31(9), 374. <https://doi.org/10.3390/curroncol31090374>
- El-Banby, G. M., Salem, N. S., Tafweek, E. A. y Abd El-Azziz, E. N. (2024). Automated detection of mammography anomalies using a deep U-Net framework. *Complex & Intelligent Systems*. <https://doi.org/10.1007/s40747-024-01254-0>

No.	Rol	Descripción
1	Conceptualización	Guillermo Pérez Ibarra; Santiago Tello-Mijares
2	Curación de datos	Guillermo Pérez Ibarra
3	Análisis formal	Guillermo Pérez Ibarra; Santiago Tello-Mijares
4	Obtención de fondos	Santiago Tello-Mijares; Francisco Flores García
5	Investigación	Guillermo Pérez Ibarra
6	Methodología	Guillermo Pérez Ibarra; Santiago Tello-Mijares
7	Administración del proyecto	Guillermo Pérez Ibarra; Santiago Tello-Mijares
8	Recursos	Santiago Tello-Mijares; Francisco Flores García
9	Software	Guillermo Pérez Ibarra; Santiago Tello-Mijares
10	Supervision	Santiago Tello-Mijares; Francisco Flores García
11	Validación	Guillermo Pérez Ibarra; Santiago Tello-Mijares
12	Visualización	Guillermo Pérez Ibarra
13	Redacción - borrador original	Guillermo Pérez Ibarra
14	Redacción - revisión y edición	Guillermo Pérez Ibarra; Santiago Tello-Mijares