



UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE CUENCA
CARRERA DE BIOMEDICINA

COMPARATIVA DE REDES DE APRENDIZAJE PROFUNDO EMPLEANDO TRANSFER
LEARNING PARA DETECCIÓN DE CÁNCER DE MAMA EN EL CORPUS CBIS-DDSM

Trabajo de titulación previo a la obtención del
título de Ingeniero Biomédico

AUTOR: ERICK GEOVANNY DUTÁN CRIOLLO

TUTOR: ING. VLADIMIR ESPARTACO ROBLES BYKBAEV, PHD.

Cuenca - Ecuador

2024

**CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE
TITULACIÓN**

Yo, Erick Geovanny Dután Criollo con documento de identificación N° 0105918825, manifiesto que:

Soy el autor y responsable del presente trabajo; y, autorizo a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Cuenca, 30 de julio del 2024

Atentamente,



Erick Geovanny Dután Criollo

0105918825

**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE
TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Yo, Erick Geovanny Dután Criollo con documento de identificación N° 0105918825, expreso mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del Artículo académico: “Comparativa de redes de aprendizaje profundo empleando transfer learning para detección de cáncer de mama en el corpus CBIS-DDSM”, el cual ha sido desarrollado para optar por el título de: Ingeniero Biomédico, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Cuenca, 30 de julio del 2024

Atentamente,



Erick Geovanny Dután Criollo

0105918825

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Vladimir Espartaco Robles Bykbaev con documento de identificación N° 0300991817, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: COMPARATIVA DE REDES DE APRENDIZAJE PROFUNDO EMPLEANDO TRANSFER LEARNING PARA DETECCIÓN DE CÁNCER DE MAMA EN EL CORPUS CBIS-DDSM, realizado por Erick Geovanny Dután Criollo con documento de identificación N° 0105918825, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Cuenca, 30 de julio del 2024

Atentamente,



Ing. Vladimir Espartaco Robles Bykbaev, PHD

0300991817

COMPARATIVA DE REDES DE APRENDIZAJE PROFUNDO EMPLEANDO TRANSFER LEARNING PARA DETECCIÓN DE CÁNCER DE MAMA EN EL CORPUS CBIS-DDSM

COMPARISON OF DEEP LEARNING NETWORKS USING TRANSFER LEARNING FOR BREAST CANCER DETECTION IN THE CBIS-DDSM CORPUS

Erick Geovanny Dután Criollo¹, Vladimir Espartaco Robles Bykbaev²

Abstract (spanish)

El objetivo de este estudio es comparar diversas arquitecturas de redes de aprendizaje profundo utilizando la técnica de transfer learning para la detección de cáncer de mama en imágenes del corpus CBIS-DDSM. Se evaluaron modelos como VGG16, ResNet152 y EfficientNet, entrenados y afinados con imágenes mamográficas preprocesadas. Los resultados muestran que el modelo ResNet50 obtiene el mejor desempeño en términos de precisión y sensibilidad, destacándose como una herramienta prometedora para el apoyo en el diagnóstico temprano del cáncer de mama. Además, el estudio incluye la aplicación de técnicas de procesamiento de imágenes como la mejora del contraste utilizando CLAHE y operaciones morfológicas. Los resultados indican que las mamografías procesadas muestran un rendimiento superior. La red ResNet50 mejorada con CLAHE alcanzó una precisión del 68.2%, mientras que con operaciones morfológicas logró un 67.7%. Sin embargo, la red VGG19 con las mamografías normales mostró el mejor rendimiento, con una exactitud del 69.1%.

Keywrods (spanish): aprendizaje profundo, aprendizaje por transferencia, cáncer de mama, CBIS-DDSM, redes neuronales, clasificación de imágenes.

Abstract

The objective of this study is to compare various deep learning network architectures using transfer learning for breast cancer detection in images from the CBIS-DDSM corpus. Models such as VGG16, ResNet50, and EfficientNet were evaluated, trained, and fine-tuned with preprocessed mammographic images. The results show that the ResNet152 model achieves the best performance in terms of accuracy and sensitivity, standing out as a promising tool for supporting the early diagnosis of breast cancer. Additionally, the study includes the application of image processing techniques such as contrast enhancement using CLAHE and morphological operations. The results indicate that processed mammograms show superior performance. The ResNet50 network enhanced with CLAHE achieved an accuracy of 68.2%, while with morphological operations it achieved 67.7%. However, the VGG19 network with normal mammograms showed the best performance, with an accuracy of 69.1%.

Keywords: deep learning, transfer learning, breast cancer, CBIS-DDSM, convolutional neural networks, image classification.

¹ Grupo de investigación en Inteligencia Artificial y Tecnologías de Asistencia, Universidad Politécnica Salesiana, Ecuador

² Grupo de investigación en Inteligencia Artificial y Tecnologías de Asistencia, Universidad Politécnica Salesiana, Ecuador

1. Introducción

En todo el mundo, el cáncer de mama en mujeres ha superado al cáncer de pulmón como el cáncer diagnosticado con mayor frecuencia. Se calcula que se diagnosticaron 2,261,419 casos nuevos en mujeres de todo el mundo en 2020. En las naciones subdesarrolladas, la mayoría de las muertes por cáncer de seno se producen de forma precipitada, la carga de morbilidad por esta enfermedad es desproporcionadamente mayor entre las mujeres menores de 70 años. La cantidad de mujeres en América Latina y el Caribe afectadas por la enfermedad antes de los 50 años (32%) es significativamente mayor que en América del Norte (19%). En América Latina y el Caribe, hubo más de 210,000 nuevos diagnósticos de cáncer de mama en 2020 y casi 68,000 muertes [1].

En Ecuador, las cifras del INEC para 2017 indican que la mortalidad por cáncer de mama se mantiene como una preocupación significativa en Ecuador. Entre las mujeres, ocupa el undécimo lugar en la lista de causas generales de muerte, con 670 defunciones ese año, mientras que, entre los hombres, las defunciones fueron tres, con una tasa de mortalidad de 3,99 por cada 100.000 habitantes. Además, el análisis de la mortalidad por localización de tumores destaca la importancia de abordar el cáncer de mama, ya que ocupa el primer lugar entre las mujeres, seguido de otras ubicaciones como estómago, cuello uterino y pulmones [2].

Muchas supervivientes han de adaptarse a las secuelas físicas derivadas de los tratamientos oncológicos como mastectomía, cicatrices, linfedema, tratamientos hormonales, quimioterapia, radioterapia o trasplante de médula ósea. Aunque muchas mujeres se enfrentan satisfactoriamente a la experiencia de los tratamientos, otras pueden sentirse emocionalmente afectadas por cambios en su imagen corporal y su feminidad [3]. Estudio prospectivo de 2008 a 2012 con 67 pacientes con cáncer de mama, como grupo de control fueron estudiadas 33 pacientes con cáncer de mama benigno reveló que hubo reducción significativa del "deseo sexual", "excitación sexual" y "orgasmo" en comparación con el grupo de control [4]. Un estudio del impacto psicológico en supervivientes con mastectomía, cirugía conservadora y reconstrucción mamaria reveló diferencias importantes en cuanto a su calidad vida, la imagen corporal era más favorable en mujeres con cirugía reparadora, por el contrario, se presentaba un mayor estrés psicológico en mujeres con

mastectomía. Las preocupaciones psicológicas más comunes incluyen el temor a la recurrencia, la incertidumbre sobre el futuro, la ansiedad y la persistente preocupación por la amenaza de que la enfermedad regrese [3]. El regreso al trabajo puede ser más complicado cuando se presentan procesos psicológicos, a veces causando más incapacidad que el propio cáncer y sus consecuencias. Se estima que el 36% de las mujeres con cáncer de mama experimenta depresión y requiere apoyo psiquiátrico, mientras que el 55% sufre algún tipo de trastorno emocional, ya sea por ansiedad o trastorno adaptativo [5].

La detección temprana del cáncer de mama es crucial para aumentar las tasas de supervivencia. Las técnicas de imagen, como la mamografía, son esenciales en este proceso. El diagnóstico oportuno de los tumores de seno es crucial, ya que su detección en etapas iniciales puede modificar el pronóstico de la enfermedad y mejorar las probabilidades de supervivencia. La exploración clínica de la mama, la ecografía, la mastografía y la toma de biopsia son las pruebas tradicionales que se utilizan para detectar el cáncer de mama. Por lo general, estas pruebas son costosas, invasivas y en la mayoría de los casos dolorosas, lo que las hace ineficaces en la detección temprana del cáncer y en la reducción de la mortalidad [6]. La detección temprana y el seguimiento médico son fundamentales para un manejo adecuado de la salud mamaria. Como se puede observar en la Fig. 1, el 32% de casos de cáncer de mamá se diagnosticaron en los estadios III y IV cuando las alternativas de tratamiento son escasas y limitadas, el diagnóstico en los estadios tempranos muestra que la tasa de supervivencia supera el 90% [7].




Figure 1. Tasas de supervivencia por estadio [7].

Identificar el cáncer en sus etapas iniciales puede disminuir significativamente su carga económica: el tratamiento en estas fases es considerablemente menos costoso y permite a los pacientes continuar con sus actividades laborales y brindar soporte a sus familias si se les proporciona un tratamiento efectivo de manera oportuna. Se calculó que, en 2010, el costo anual total del cáncer, considerando tanto los gastos de atención médica como la pérdida de productividad, ascendió a US \$1,16 billones [1].

Si bien la mamografía permite un diagnóstico oportuno la interpretación de estas es crucial para el diagnóstico temprano del cáncer de mama. Sin embargo, la calidad de esta interpretación varía según las habilidades perceptivas y cognitivas de cada radiólogo. Es fundamental que los médicos radiólogos tengan un amplio conocimiento de los posibles errores que pueden surgir al interpretar estas imágenes y sepan cómo prevenirlos, corregirlos o minimizarlos [8]. La concordancia entre los radiólogos al interpretar mamografías es limitada, y existe una significativa variabilidad tanto entre observadores como entre las interpretaciones. Esto puede ocasionar retrasos en la detección del cáncer de mama o incluso llevar a realizar biopsias innecesarias, con consecuencias físicas, económicas y psicológicas no deseadas [9].

En el campo médico, la Inteligencia Artificial ha jugado un papel crucial en aspectos como la detección temprana y el diagnóstico del cáncer de mama, utilizando métodos de aprendizaje automático y visión computacional. La mayoría de las contribuciones se han hecho en el análisis de imágenes de ultrasonido, termografía y mastografía, para identificar patrones que diferencian a mujeres con enfermedades mamarias de las que no tienen [6].

Se ha realizado una revisión de la literatura de las investigaciones de los últimos 5 años, que proporciona un panorama completo de los avances y descubrimientos más recientes en el diagnóstico por inteligencia artificial. En el contexto de esta investigación nos permite entender las metodologías, teorías y enfoques que han sido explorados y los que aún requieren investigación. Rao et al. [10] lograron una AUC de 0.97 y una CA de 0.858 utilizando transfer learning con un modelo de ensamble sobre el benchmark de imágenes de ultrasonido de cáncer de mama. Chakravarthy et al. [11] emplearon una arquitectura preentrenada EfficientNet-B4, alcanzando una precisión clasificatoria del 98.459% en el dataset INbreast y del 96.175% en el dataset CBIS-DDSM. Marshe et al. (2024) propusieron una red neuronal convolucional para imágenes histopatológicas de mama, obteniendo una precisión del 95.2%. Quiñones-Espín et al. [12] desarrollaron modelos YOLOv5x y YOLOv5s, logrando una sensibilidad del 80% en validación interna y del 72% en validación externa usando los datasets MIAS y Vindr-Mammo. Shaaban et al. [13] implementaron un sistema de segmentación basado en una versión mejorada de la red U-Net 3+, alcanzando una puntuación del 98.47% en el dataset INbreast FFDM. Pravin Kumar Samanta et al. [14] presentaron un nuevo modelo de CNN (Convolutional Neural Network) llamado BCI-Net aplicado al dataset BUSI, obteniendo una precisión del 97.49%. Hama Soltani et al. [15] aplicaron el modelo Mask RCNN utilizando detectron2, logrando un F1 del 95.87% en el dataset INbreast. Finalmente, Jena et al. [16] emplearon técnicas de machine learning para clasificar imágenes de ultrasonido de mama en el dataset HI VISION, alcanzando valores de precisión de 0.821 con DTR, 0.824 con ADB y 0.736 con NBY.

En la actualidad de la ciencia, se han examinado aproximadamente 10 investigaciones que emplean

redes de aprendizaje para clasificar imágenes, incluyendo mamografías, ultrasonidos e imágenes histopatológicas. Por lo tanto, aunque los avances son prometedores, la implementación práctica de estas técnicas aún enfrenta desafíos significativos en términos de recursos humanos y tecnológicos.

Este estudio se centra en la comparación de diversas redes de aprendizaje profundo empleando transfer learning para mejorar la detección de cáncer de mama en imágenes de mamografías, utilizando el corpus CBIS-DDSM, de una forma más simplificada, accesible y rápida. Se presentan los diferentes pasos a realizar en la propuesta en la Fig. 2.

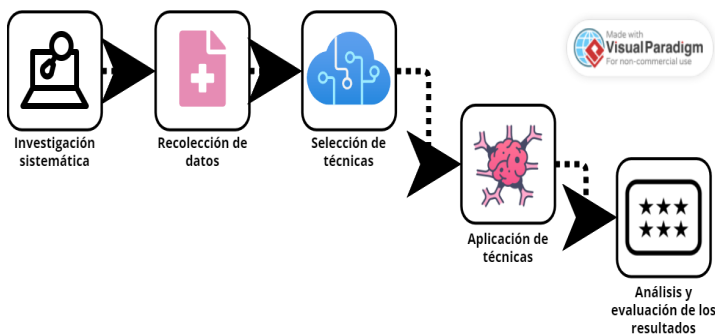


Figure 2. Diagrama de bloques de la investigación.

2. Materiales y Métodos

2.1. Recopilación de datos

El DDSM es una colección de mamografías provenientes de diversas instituciones: el Hospital General de Massachusetts, la Escuela de Medicina de la Universidad Wake Forest, el Hospital del Sagrado Corazón y la Escuela de Medicina de la Universidad Washington en St. Louis. Los desarrolladores originales del DDSM obtuvieron los consentimientos necesarios de las pacientes. Los casos están anotados con regiones de interés (ROI) para calcificaciones y masas, así como otra información relevante que puede ser útil para los algoritmos.

2.2. Tratamiento de imágenes

2.2.1. Aumento de imágenes

Uno de los problemas más comunes para los modelos de aprendizaje profundo es el sobreajuste debido a la limitada cantidad de muestras [17]. Para aumentar las muestras, se utilizaron tres funciones que generan imágenes a partir de una original: rotación aleatoria de 55 grados, desenfoque gaussiano y corte aleatorio, con eso se logra poder entrenar y validar las redes de aprendizaje

con un conjunto de imágenes más grande. En la tabla 1 se realiza un conteo de las imágenes aumentadas en entrenamiento y validación.

Tabla 1: Resumen de aumento de mamografías digitales

	Entrenamiento		Validación	
	Empleadas	Aumentadas	Empleadas	Aumentadas
Benignas	720	1407	167	278
Malignas	507	1404	70	280

Se realizó una comparación de la imagen original respecto a las 3 transformaciones realizadas. Se puede observar en la Fig. 3.




Figure 3. Resultados del aumento de imágenes, imagen original (a), imagen con desenfoque gaussiano (b), imagen con corte aleatorio (c), imagen con rotación aleatoria (d).

2.2.2. Ecualización adaptativa del histograma limitada por el contraste

El método CLAHE (Constrast Limited Adaptive Histogram Equalization). Es utilizada en una variedad de aplicaciones, en las que se incluye el procesamiento de imágenes médicas debido a su eficacia [18]. Es una técnica de procesamiento de imágenes que mejora el contraste de una imagen, dividiéndola en pequeñas regiones llamadas “tiles” y aplica una ecualización de histograma, y los utiliza para redistribuir los valores de brillo de la imagen, mejorando el contraste local. Se visualizan los cambios en la Fig. 4.




Figure 4. Resultados de la aplicación de la técnica CLAHE (b) en comparación con la imagen original (a)

2.2.3. Operaciones morfológicas

En el procesamiento de imágenes, los operadores morfológicos juegan un papel crucial en la manipulación de las estructuras presentes en la imagen. [19] Dos de los operadores fundamentales son la erosión y la dilatación, que se definen de la siguiente manera:

Erosión: La erosión es un operador que reduce el tamaño de los objetos presentes en una imagen. Este operador es útil para eliminar detalles pequeños y aumentar el tamaño de los agujeros en la imagen. Se define como:

$$A \ominus B = \min_u, v \{A(x + u, y + v) - B(u, v)\} \quad (1)$$

Dilatación: La dilatación, por otro lado, actúa de manera inversa a la erosión. Incrementa el tamaño de los objetos y reduce el tamaño de los agujeros en la imagen. La dilatación es útil para rellenar huecos y conectar elementos disjuntos en la imagen. Se representa como:

$$A \oplus B = \max_u, v \{A(x - u, y - v) + B(u, v)\} \quad (3)$$

Operadores Compuestos

Además de la erosión y la dilatación, existen operadores compuestos que combinan ambos procesos para obtener efectos más sofisticados:

Apertura: La apertura se define como la erosión seguida de una dilatación. Este operador se utiliza para eliminar conexiones débiles entre objetos y pequeños detalles de la imagen. Matemáticamente, la apertura se representa como:

$$A \circ B = (A \ominus B) \oplus B \quad (4)$$

Cierre: El cierre se define como la dilatación seguida de una erosión. Este operador es útil para eliminar pequeños

agujeros y rellenar grietas en la imagen. Matemáticamente, el cierre se representa como:

$$A \cdot B = (A \oplus B) \ominus B \quad (5)$$

En la Fig. 5 se puede visualizar la comparación de la imagen original respecto a la imagen con la aplicación de las técnicas morfológicas.




Figure 5. Resultados de la aplicación de las operaciones morfológicas (b) en comparación con la imagen original (a).

2.3. Redes neuronales

2.3.1. ResNet 152

Es una red neuronal profunda diseñada para tareas de reconocimiento de imágenes, conocida por su estructura de 152 capas. Pertenece a la familia de redes residuales (ResNet) introducida para superar el problema del degradado en redes profundas. Con 152 capas, es una de las arquitecturas más profundas, permitiendo una representación jerárquica muy detallada de las características de las imágenes. Utiliza bloques residuales que permiten el flujo directo de la información a través de la red, mitigando el problema del gradiente desaparecido y facilitando el entrenamiento de redes profundas [20].

2.3.2. Efficient Net

Esta arquitectura emplea un método de escalado compuesto para optimizar simultáneamente la profundidad, la anchura y la resolución de la red, permitiendo así una alta precisión sin sacrificar la eficiencia computacional. Se compone de una red troncal, que extrae características de las imágenes de entrada, y una red principal, que lleva a cabo la clasificación final. La red troncal utiliza una combinación de capas convolucionales móviles de cuello de botella invertido para capturar correlaciones espaciales y de canal en la entrada. Por su parte, la red

principal utiliza una combinación de capas de agrupación de promedios globales y capas totalmente conectadas para realizar la clasificación final [21].

2.3.3. VGG 19

El modelo VGG19, también conocido como VGGNet-19, es una arquitectura de red neuronal profunda que se caracteriza por su simplicidad y efectividad en la clasificación de imágenes. Fue desarrollado por el Visual Geometry Group de la Universidad de Oxford y es una evolución del modelo VGG16, con la diferencia principal de que VGG19 cuenta con 19 capas de pesos, mientras que VGG16 tiene 16. Esta arquitectura se utilizó en la competencia ImageNet, donde los desarrolladores recortaron los parches centrales de 224x224 píxeles en cada imagen para mantener un tamaño de entrada consistente [22].

3. Resultados y discusión

Los resultados obtenidos en la investigación se presentan en esta sección en detalle. La evaluación se realizó con el conjunto de datos aumentados de CBIS-DDSM de los tres tipos de imágenes: normales, con mejora de contraste y con operaciones morfológicas. Para el entrenamiento y validación de las imágenes se usaron las tres redes anteriormente descritas. Las redes EfficientNet, ResNet 152 y VGG 19 incluyen un ajuste de hiperparámetros tales como una tasa de aprendizaje de 0.001, un momento de 0.17 con 25 épocas, un tamaño de lote de 8, y el optimizador utilizado es un algoritmo de descenso de gradiente estocástico. En cada una de las pruebas se evaluó la pérdida y la exactitud de cada época. Todas las pruebas se realizaron utilizando los recursos GPU del Google Colab.

3.1. Métricas de evaluación

Para evaluar el desempeño de las pruebas, se utilizaron varias métricas de evaluación.

Verdaderos positivos (TP): Casos en los que tanto la clase predicha como la clase real son positivas, indicando que el modelo ha clasificado correctamente con una etiqueta positiva.

Falsos positivos (FP): Casos en los que la clase predicha es positiva pero la clase real es negativa, lo que significa que el modelo ha clasificado incorrectamente con una etiqueta positiva.

Verdaderos negativos (TN): Casos en los que tanto la clase predicha como la clase real son negativas, mostrando que el modelo ha clasificado correctamente con una etiqueta negativa.

Falsos negativos (FN): Casos en los que la clase predicha es negativa pero la clase real es positiva, lo que indica que el modelo ha clasificado incorrectamente con una etiqueta negativa.

Exactitud: Esta métrica mide el número total de casos clasificados correctamente. En el contexto del clasificador de anomalías, la exactitud refleja la correcta clasificación de las imágenes como malignas o benignas en el modelo.

$$Exactitud = \frac{TP+TN}{TP+TN+FP+FN} \quad (5)$$

3.2. Resultados con mamografías normales

3.2.1. ResNet 152

Para este caso, el mejor valor de exactitud global obtenido fue del 64.1%. Además, se calculó la exactitud específica para las clases: en el caso de las mamografías malignas, la exactitud fue del 67.4%, y en el caso de las mamografías benignas, fue del 60.8%. En las Figuras 6, 7 y 8, se pueden observar las gráficas de pérdida, exactitud por época y una matriz de confusión, respectivamente.

- **Gráfica de pérdida:**




Figura 6. Gráfica de pérdida (ResNet) con mamografías normales.

- **Gráfica de exactitud:**




Figura 7. Gráfica de exactitud (ResNet) con mamografías normales

- **Matriz de confusión:**




Figura 8. Matriz de confusión (ResNet) con mamografías normales.

3.2.2. EfficientNet

En este caso, el mejor valor de exactitud global obtenido fue del 64.4%. Además, se calculó la exactitud específica para las clases: en el caso de las mamografías malignas, la exactitud fue del 71.3%, y en el caso de las mamografías benignas, fue del 57.6%. En las Figuras 9, 10 y 11, se pueden observar las gráficas de pérdida, exactitud por época y una matriz de confusión, respectivamente.

- **Gráfica de pérdida:**

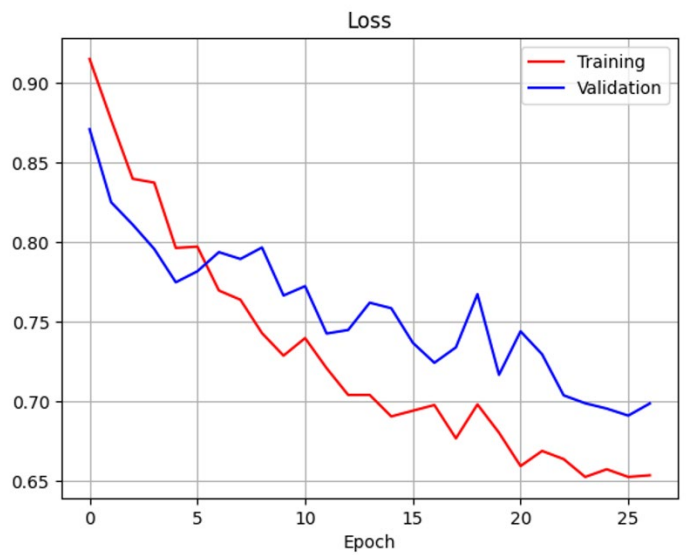


Figura 9. Gráfica de pérdida (EfficientNet) con mamografías normales.

- **Gráfica de exactitud:**

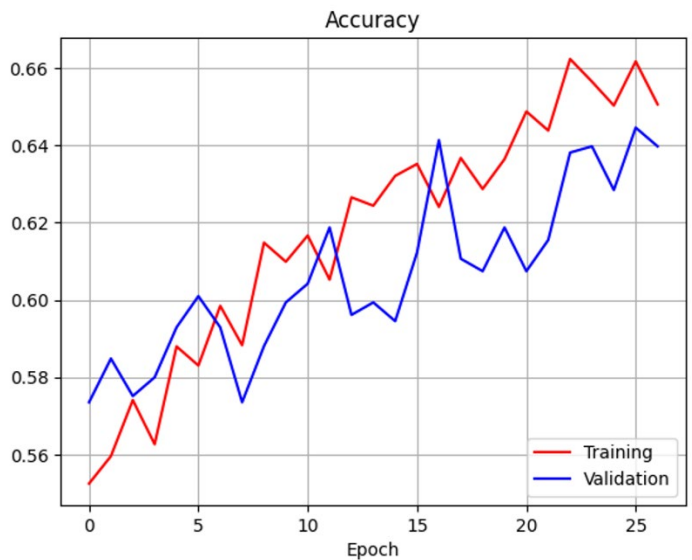


Figura 10. Gráfica de exactitud (EfficientNet) con mamografías normales.

- **Matriz de confusión:**




Figura 11. Matriz de confusión (EfficientNet) con mamografías normales.




Figura 13. Gráfica de exactitud (VGG19) con mamografías normales.

3.2.3. VGG 19

Para esta red, el mejor valor de exactitud global obtenido fue del 69.1%. Además, se calculó la exactitud específica para las clases: en el caso de las mamografías malignas, la exactitud fue del 70.3%, y en el caso de las mamografías benignas, fue del 68.0%. En las Figuras 12, 13 y 14, se pueden observar las gráficas de pérdida, exactitud por época y una matriz de confusión, respectivamente.

- **Gráfica de pérdida:**




Figura 12. Gráfica de pérdida (VGG19) con mamografías normales.

- **Gráfica de exactitud:**

- **Matriz de confusión:**

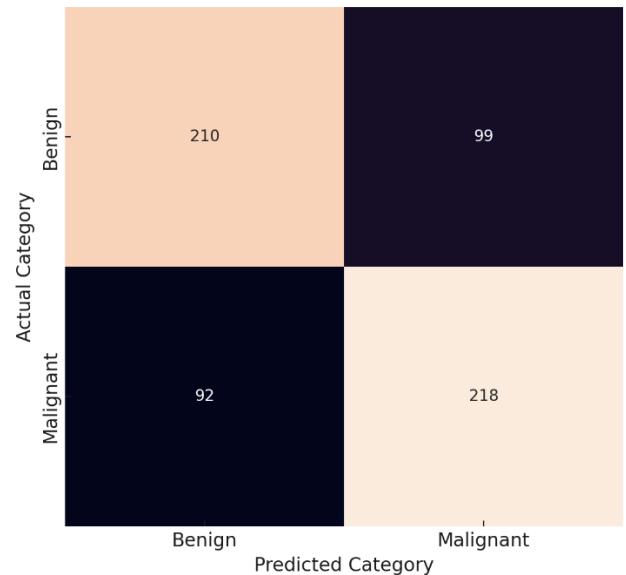


Figura 14. Matriz de confusión (VGG19) con mamografías normales.

3.3. Resultados con mamografías con CLAHE

3.3.1. ResNet 152

Para las mamografías con la técnica CLAHE, el mejor valor de exactitud global obtenido fue del 68.2%. Además, se calculó la exactitud específica para las clases: en el caso de las mamografías malignas, la exactitud fue del 70.5%, y en el caso de las mamografías benignas, fue del 66.1%. En las Figuras 15, 16 y 17, se pueden observar las gráficas de pérdida, exactitud por época y una matriz de confusión, respectivamente.

- **Gráfica de pérdida:**




Figura 15. Gráfica de pérdida (ResNet) con mamografías con CLAHE.

- **Gráfica de exactitud:**




Figura 16. Gráfica de exactitud (ResNet) con mamografías con CLAHE.

- **Matriz de confusión:**

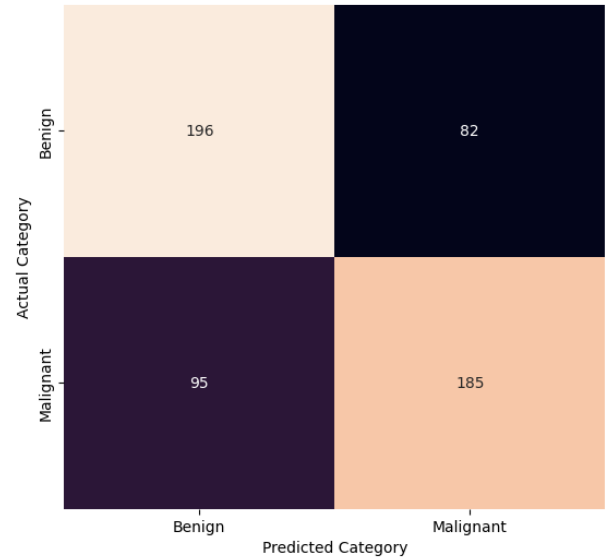


Figura 17. Matriz de confusión (ResNet) con mamografías con CLAHE.

3.3.2. EfficientNet

Para este caso, el mejor valor de exactitud global obtenido fue del 62.01%. Además, se calculó la exactitud específica para las clases: en el caso de las mamografías malignas, la exactitud fue del 65.4%, y en el caso de las mamografías benignas, fue del 58.6%. En las Figuras 18, 19 y 20, se pueden observar las gráficas de pérdida, exactitud por época y una matriz de confusión, respectivamente.

- **Gráfica de pérdida:**




Figura 18. Gráfica de pérdida (EfficientNet) con mamografías con CLAHE.

- **Gráfica de exactitud:**




Figura 19. Gráfica de exactitud (EfficientNet) con mamografías con CLAHE.

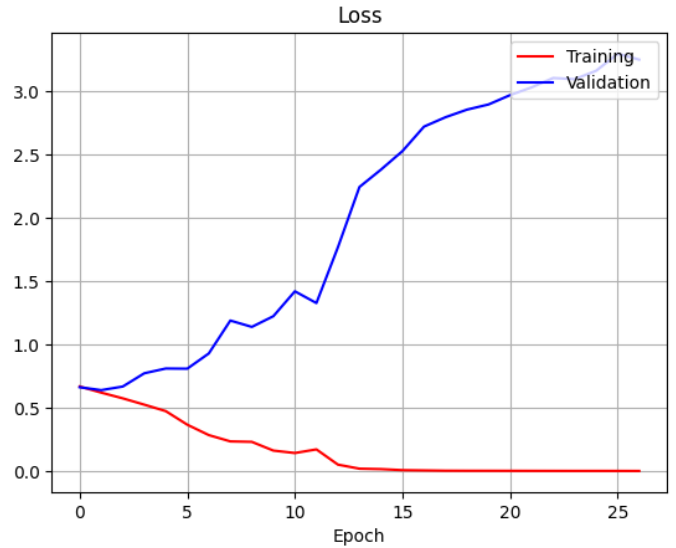


Figura 21. Gráfica de pérdida (VGG19) con mamografías con CLAHE.

- **Matriz de confusión:**

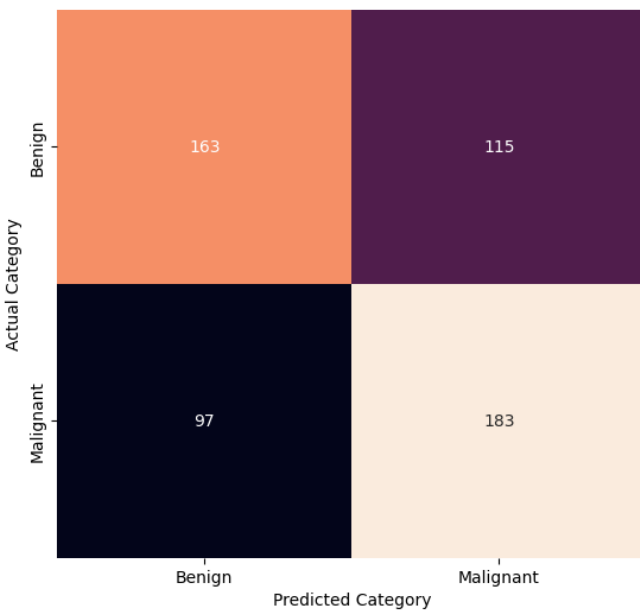


Figura 20. Matriz de confusión (EfficientNet) con mamografías con CLAHE.

- **Gráfica de exactitud:**

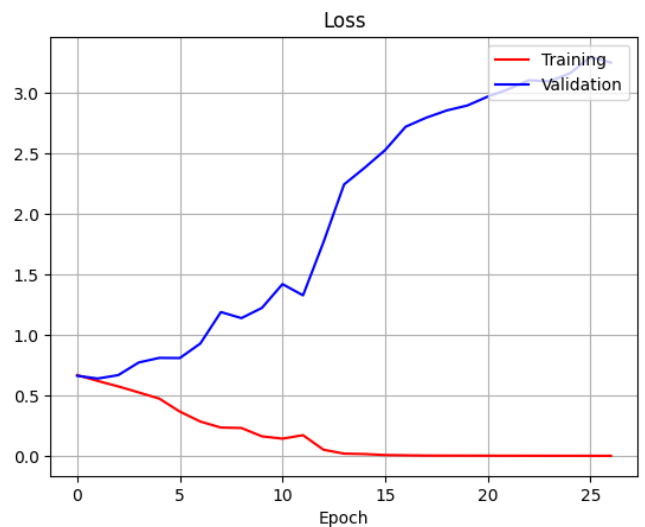


Figura 22. Gráfica de exactitud (VGG19) con mamografías con CLAHE.

- **Matriz de confusión:**

3.3.3. VGG 19

En la red VGG 19, el mejor valor de exactitud global obtenido fue del 63.6%. Además, se calculó la exactitud específica para las clases: en el caso de las mamografías malignas, la exactitud fue del 69.3%, y en el caso de las mamografías benignas, fue del 57.9%. En las Figuras 21, 22 y 23, se pueden observar las gráficas de pérdida, exactitud por época y una matriz de confusión, respectivamente.

- **Gráfica de pérdida:**




Figura 23. Matriz de confusión (VGG19) con mamografías con CLAHE.

3.4. Resultados con mamografías con operaciones morfológicas

3.4.1. ResNet 152

Para este caso, el mejor valor de exactitud global obtenido fue del 67.7%. Además, se calculó la exactitud específica para las clases: en el caso de las mamografías malignas, la exactitud fue del 79.3%, y en el caso de las mamografías benignas, fue del 56.1%. En las Figuras 24, 25 y 26, se pueden observar las gráficas de pérdida, exactitud por época y una matriz de confusión, respectivamente.

- Gráfica de pérdida:




Figura 24. Gráfica de pérdida (ResNet) con mamografías con operaciones morfológicas.

- Gráfica de exactitud:




Figura 25. Gráfica de exactitud (ResNet) con mamografías con operaciones morfológicas.

- Matriz de confusión:

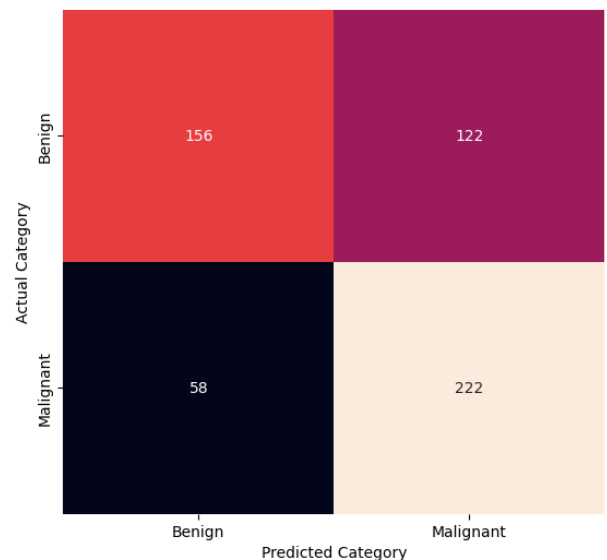


Figura 26. Matriz de confusión (ResNet) con mamografías con operaciones morfológicas.

3.4.2. EfficientNet

Para este caso, el mejor valor de exactitud global obtenido fue del 62.3%. Además, se calculó la exactitud específica para las clases: en el caso de las mamografías malignas, la exactitud fue del 62.5%, y en el caso de las mamografías benignas, fue del 62.2%. En las Figuras 27, 28 y 29, se pueden observar las gráficas de pérdida,

exactitud por época y una matriz de confusión, respectivamente.

- **Gráfica de pérdida:**

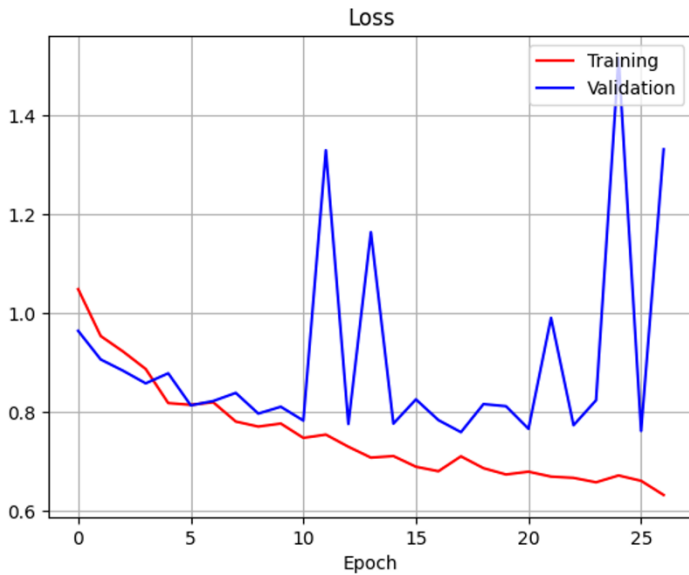


Figura 27. Gráfica de pérdida (EfficientNet) con mamografías con operaciones morfológicas.

- **Gráfica de exactitud:**




Figura 28. Gráfica de exactitud (EfficientNet) con mamografías con operaciones morfológicas.

- **Matriz de confusión:**

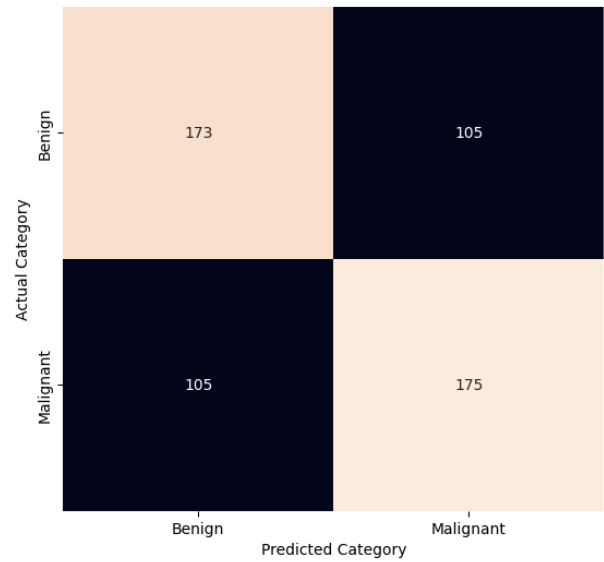


Figura 29. Matriz de confusión (EfficientNet) con mamografías con operaciones morfológicas.

3.4.3. VGG 19

El mejor valor de exactitud global obtenido, para este caso, fue del 65.7%. Además, se calculó la exactitud específica para las clases: en el caso de las mamografías malignas, la exactitud fue del 72.9%, y en el caso de las mamografías benignas, fue del 58.6%. En las Figuras 30, 31 y 32, se pueden observar las gráficas de pérdida, exactitud por época y una matriz de confusión, respectivamente.

- **Gráfica de pérdida:**

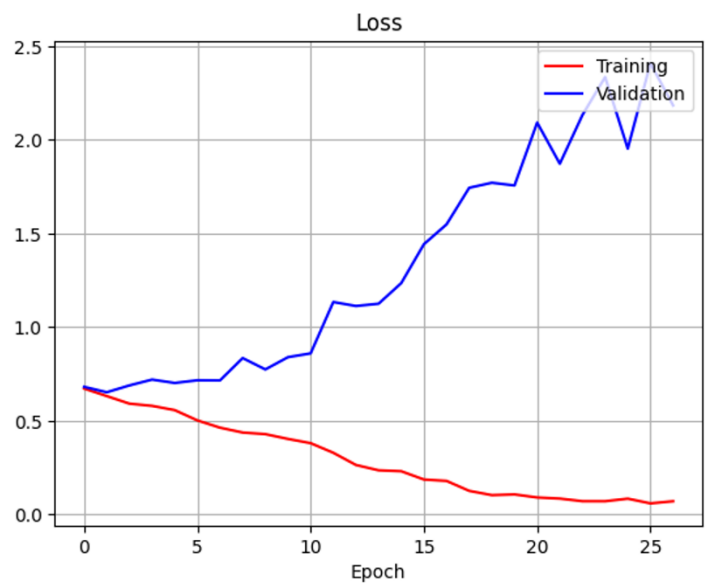


Figura 30. Gráfica de pérdida (VGG19) con mamografías con operaciones morfológicas.

- **Gráfica de exactitud:**

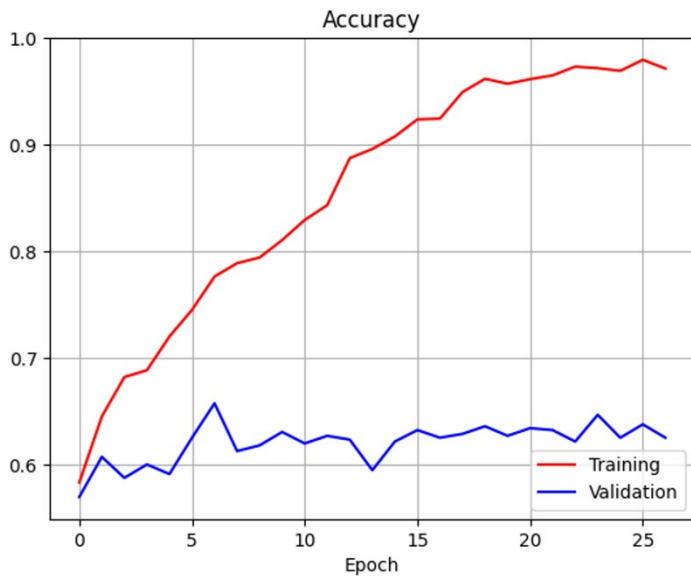


Figura 31. Gráfica de exactitud (VGG19) con mamografías con operaciones morfológicas.

• **Matriz de confusión:**

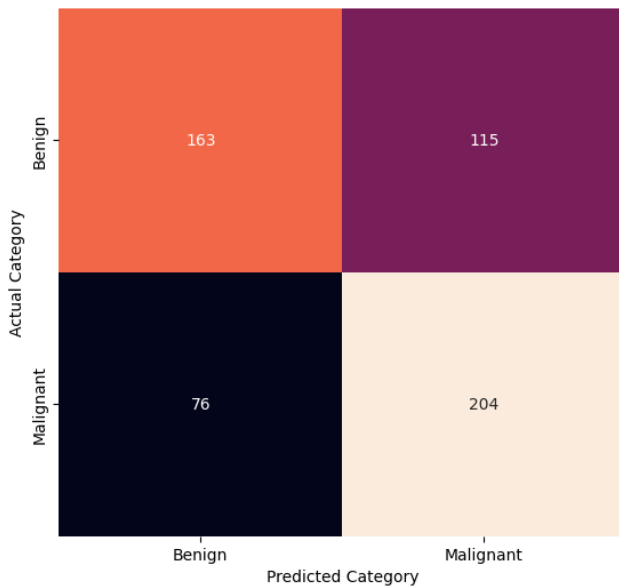


Figura 32. Matriz de confusión (VGG19) con mamografías con operaciones morfológicas.

3.5. Comparación de los resultados

La tabla 2 muestra la comparación de los resultados de los 3 tipos de imágenes con las diferentes redes, muestra también el tiempo en el que se ejecutó.

Tabla 2: Resumen de resultados

	Acc (%)	Tiempo (m)
Mamografías normales		
ResNet 152	64.1	39m 44s
EfficientNet	64.4	50m 39s
VGG 19	69.1	82m 16s
Mamografías CLAHE		
ResNet 152	68.2	69m 5s
EfficientNet	62.0	43m 47s
VGG 19	63.6	70m 25s
Mamografías Morfológicas		
ResNet 152	67.7	75m 26s
EfficientNet	62.3	43m 26s
VGG 19	65.7	73m 2s

Mamografías Normales: VGG19 obtuvo la mejor precisión con un 69.1%, aunque con un tiempo de entrenamiento considerablemente mayor (82m 16s) comparado con ResNet 152 y EfficientNet.

Mamografías con CLAHE: ResNet 152 tuvo el mejor rendimiento con una precisión del 68.2%. EfficientNet, aunque rápida, mostró una precisión significativamente menor (62%).

Mamografías Morfológicas: ResNet 152 nuevamente mostró el mejor rendimiento con una precisión del 67.7%, seguida por VGG19 y EfficientNet.

4. Conclusiones

El artículo propone comparar redes de aprendizaje profundo aplicadas a mamografías digitales obtenidas de la base de datos pública CBIS-DDSM. El enfoque incluye investigaciones importantes que comienzan con la selección de la base de datos y culminan con la comparación y análisis del rendimiento de las redes. Inicialmente, se aplican dos técnicas de procesamiento de imágenes: mejora del contraste utilizando CLAHE y operaciones morfológicas. Las redes de aprendizaje profundo se entrenan con las imágenes procesadas y se comparan con los resultados obtenidos utilizando las imágenes originales. Los resultados indican que las mamografías procesadas muestran un rendimiento superior. Con la red ResNet 152, aquellas mejoradas con CLAHE alcanzan una precisión del 68.2%, mientras que las mejoradas con operaciones morfológicas logran un 67.7%. Sin embargo, la red VGG19 con las mamografías normales muestra el mejor rendimiento, con una exactitud del 69.1%. Como dirección futura, se propone

mejorar estos resultados mediante un nuevo modelo de aprendizaje profundo que extraiga características de otras redes pre-entrenadas.

Referencias

- [1] «Cáncer de mama - OPS/OMS | Organización Panamericana de la Salud». Accedido: 23 de marzo de 2024. [En línea]. Disponible en: <https://www.paho.org/es/temas/cancer-mama>
- [2] Instituto Nacional de Estadística y Censos, «El cáncer de mama en Ecuador», Instituto Nacional de Estadística y Censos. Accedido: 23 de marzo de 2024. [En línea]. Disponible en: <https://www.ecuadorencifras.gob.ec/el-cancer-de-mama-en-ecuador/>
- [3] C. G. Vivar, «Impacto psicosocial del cáncer de mama en la etapa de larga supervivencia: propuesta de un plan de cuidados integral para supervivientes», *Aten Primaria*, vol. 44, n.º 5, pp. 288-292, may 2012, doi: 10.1016/j.aprim.2011.07.011.
- [4] D. Vaidakis et al., «Female sexuality after female cancer treatment: a clinical issue», *Eur J Gynaecol Oncol*, vol. 35, n.º 6, pp. 635-640, 2014.
- [5] J. M. Vicente Pardo, A. López-Guillén García, J. M. Vicente Pardo, y A. López-Guillén García, «Problemas y factores psicológicos en el retorno al trabajo tras incapacidad temporal prolongada por cáncer de mama», *Medicina y Seguridad del Trabajo*, vol. 63, n.º 248, pp. 245-259, sep. 2017.
- [6] H. Ketelhohn, F. Meza, C. Aguilar, K. Barrantes, y S. Ibañez, «Aplicación de la inteligencia artificial en la salud pública para el diagnóstico temprano y tamizaje de enfermedades oncológicas», *Revista Ciencia y Salud Integrando Conocimientos*, vol. 8, pp. 23-29, jun. 2024, doi: 10.34192/cienciaysalud.v8i2.582.
- [7] W. Tarupi, *Boletín Epidemiológico. Cáncer de mama*. 2021.
- [8] L. Cataliotti et al., «Guidelines on the standards for the training of specialised health professionals dealing with breast cancer», *European Journal of Cancer*, vol. 43, n.º 4, pp. 660-675, mar. 2007, doi: 10.1016/j.ejca.2006.12.008.
- [9] K. García, J. Ocampo, M. Pardo, T. Aguilar, C. Ruiz, y A. Castaño, «Calidad de las imágenes, la lectura y el servicio de mamografía en cuatro centros de imagenología de Manizales, Colombia», *Biomédica*, vol. 41, pp. 52-64, mar. 2021, doi: 10.7705/biomedica.5135.
- [10] K. S. Rao et al., «Intelligent Ultrasound Imaging for Enhanced Breast Cancer Diagnosis: Ensemble Transfer Learning Strategies», *IEEE Access*, vol. 12, pp. 22243-22263, 2024, doi: 10.1109/ACCESS.2024.3358448.
- [11] S. Chakravarthy, B. Nagarajan, V. V. Kumar, T. R. Mahesh, R. Sivakami, y J. R. Annand, «Breast Tumor Classification with Enhanced Transfer Learning Features and Selection Using Chaotic Map-Based Optimization», *Int J Comput Intell Syst*, vol. 17, n.º 1, p. 18, feb. 2024, doi: 10.1007/s44196-024-00409-8.
- [12] A. E. Quiñones-Espín, M. Perez-Diaz, R. M. Espín-Coto, D. Rodriguez-Linares, y J. D. Lopez-Cabrera, «Automatic detection of breast masses using deep learning with YOLO approach», *Health and Technology*, vol. 13, n.º 6, pp. 915-923, 2023, doi: 10.1007/s12553-023-00783-x.
- [13] S. M. Shaaban, M. Nawaz, Y. Said, y M. Barr, «An Efficient Breast Cancer Segmentation System based on Deep Learning Techniques», *Engineering, Technology and Applied Science Research*, vol. 13, n.º 6, pp. 12415-12422, 2023, doi: 10.48084/etasr.6518.
- [14] P. K. Samanta, N. K. Rout, y G. Panda, «A novel deep CNN model for improved breast cancer detection using ultrasound images», en *2023 International Conference on Communication, Circuits, and Systems (IC3S)*, may 2023, pp. 1-4. doi: 10.1109/IC3S57698.2023.10169383.
- [15] H. Soltani, M. Amroune, B. Issam, y M. Y. Haouam, *Breast Cancer Lesion Detection and Segmentation Based On Mask R-CNN*. 2021. doi: 10.1109/ICRAMI52622.2021.9585913.
- [16] K. K. Jena y K. P. K., «Classification of Breast Ultrasound Images: An Analysis Using Machine Intelligent Based Approach», *International Journal of Management, Technology and Social Sciences (IJMTS)*, vol. 7, n.º 2, Art. n.º 2, ago. 2022, doi: 10.47992/IJMTS.2581.6012.0220.
- [17] C. Shorten y T. M. Khoshgoftaar, «A survey on Image Data Augmentation for Deep Learning», *Journal of Big Data*, vol. 6, n.º 1, p. 60, jul. 2019, doi: 10.1186/s40537-019-0197-0.

- [18] B. S. Rao, «Dynamic Histogram Equalization for contrast enhancement for digital images», *Applied Soft Computing*, vol. 89, p. 106114, abr. 2020, doi: 10.1016/j.asoc.2020.106114.
- [19] H. Hassanpour, N. Samadiani, y S. M. Mahdi Salehi, «Using morphological transforms to enhance the contrast of medical images», *The Egyptian Journal of Radiology and Nuclear Medicine*, vol. 46, n.º 2, pp. 481-489, jun. 2015, doi: 10.1016/j.ejrm.2015.01.004.
- [20] S. Bangar, «Resnet Architecture Explained», Medium. Accedido: 7 de julio de 2024. [En línea]. Disponible en: <https://medium.com/@siddheshb008/resnet-architecture-explained-47309ea9283d>
- [21] Z. Jafari y E. Karami, «Breast Cancer Detection in Mammography Images: A CNN-Based Approach with Feature Selection», *Information*, vol. 14, n.º 7, Art. n.º 7, jul. 2023, doi: 10.3390/info14070410.
- [22] S. Bangar, «VGG-Net Architecture Explained», Medium. Accedido: 7 de julio de 2024. [En línea]. Disponible en: <https://medium.com/@siddheshb008/vgg-net-architecture-explained-71179310050f>