



**UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE GUAYAQUIL
CARRERA DE COMPUTACIÓN**

Uso de AlexNet como red convolucional para la clasificación de imágenes médicas en el diagnóstico de cáncer de mama

Trabajo de titulación previo a la obtención del
Título de Ingeniero en ciencias de la computación

AUTOR: JUAN DE DIOS LARA BAUTISTA

TUTOR: JOE FRAND LLERENA IZQUIERDO

Guayaquil – Ecuador

2025

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

Yo, Juan de Dios Lara Bautista con documento de identificación N° 0931061287 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.

Guayaquil, 24 de enero del año 2025

Atentamente,



Juan de Dios Lara Bautista

0931061287

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

Yo, Juan de Dios Lara Bautista con documento de identificación No. 0931061287, 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: 'Uso de AlexNet como red convolucional para la clasificación de imágenes médicas en el diagnóstico de cáncer de mama', el cual ha sido desarrollado para optar por el título de: Ingeniero en ciencias de la computación, 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.

Guayaquil, 24 de enero del año 2025

Atentamente,



Juan de Dios Lara Bautista

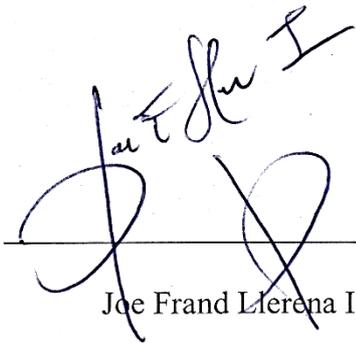
0931061287

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Joe Frand Llerena Izquierdo con documento de identificación N° 0914884879, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: USO DE ALEXNET COMO RED CONVOLUCIONAL PARA LA CLASIFICACIÓN DE IMÁGENES MÉDICAS EN EL DIAGNÓSTICO DE CÁNCER DE MAMA, realizado por Juan de Dios Lara Bautista con documento de identificación N° 0931061287, 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.

Guayaquil, 24 de enero del año 2025

Atentamente,



Joe Frand Llerena Izquierdo
0914884879

DEDICATORIA

Dedico este trabajo a mi padre, Juan Lara Mata, y a mi querida madre, Luisa Bautista Villalva, por ser el cimiento de mi esfuerzo y enseñarme que siempre hay que estar preparado para ajustarse, recalibrarse y seguir adelante. Les dedicaré cada logro que alcance a partir de ahora, porque con su confianza y amor me demostraron que ningún sueño es imposible.

A Karen Santillán, cuyo episodio de preocupación por su salud fue la chispa que me llevó a investigar sobre esta enfermedad y a elegir este tema. Aunque afortunadamente no hubo diagnóstico, aquella experiencia me reveló el poder de la tecnología como aliada en la prevención. Gracias por acompañarme en las noches de trabajo, por escuchar mis ideas y por ser mi motivación silenciosa.

A todas las personas que hoy luchan contra el cáncer, este proyecto es también por ustedes. Sé que cada día es una batalla y no es fácil saber que en la medicina actual no hay una respuesta clara para solucionar el problema, pero espero que, con avances como este el diagnóstico temprano y la ciencia se conviertan en una luz de experiencia para reducir el miedo y salvar vidas. Como se repite en la Biblia, “no temas”.

AGRADECIMIENTO

Agradezco a las personas que en algún momento compartieron conmigo en esta parte de mi vida como universitario, con risas o miedos estuvieron a mi lado impulsándome.

A mis hermanos Angie Lara con su esposo Manuel Santamaria, Pablo Lara y Ana Lara por su apoyo técnico y emocional al momento de responderme dudas a cualquier hora del día y por celebrar conmigo cada pequeño avance que doy en la vida.

Al Ing. Joe Llerena Izquierdo, MBA, MSc mi más gran agradecimiento por ser mi tutor y tener la paciencia al corregir cada detalle que tenía que pulir, su dominio en la estructuración de artículos científicos y por enseñarme a comunicar ideas complejas con claridad y rigor. Su experiencia no solo elevó este proyecto, sino que forjó en mí las bases de un investigador capaz de articular ciencia con precisión.

A mis amigos y compañeros de carrera, por las críticas y consejos que refinaron mi trabajo, con las noches de angustia de que esta era la última etapa de este ciclo y convertir el estrés en risas.

En serio, mil gracias a todos.

RESUMEN

Se puede afirmar que el estudio ha desarrollado el sistema de categorización de la imagen histopatológica que puede respaldar la temprana identificación del cáncer de mamas que se implementará a través del algoritmo de la red neuronal convolucional. A medida que la clave para la alta tasa de la enfermedad es la temprana identificación de esta, se requieren herramientas tecnológicas de auto información para mejorar las contribuciones del conocimiento de experto de salud.

La base de datos consiste en 277,524 conjuntos de imágenes de tejido mamario, la cual está clasificada como saludable y tejido con células cancerígenas con un preprocesamiento que garantiza una buena calidad y estabilidad en las clases, donde AlexNet, se implementó con modificaciones precisas en los hiperparámetros como batch size, learning rate y los números de épocas, por mencionar algunos, con la intención de obtener el mejor desempeño del modelo. Se combinaron los métodos mencionados de la normalización para tener pesos balanceados en los conjuntos y la ampliación de datos para los sobreajustes. Se resolvió hacer el análisis con la ayuda de métricas como la capacidad de detección, la precisión diagnóstica y la medición del área bajo la curva ROC, dando como resultado que la precisión superó 83% dentro del grupo de validación.

Con estos resultados se puede decir que AlexNet es eficaz para la auto categorización de imágenes histopatológicas para el sistema de apoyo en diagnósticos médicos siendo así que promoverán la incorporación de estas tecnologías en la salud, para brindar diagnósticos más rápidos y precisos para ayudar a las personas y profesionales de medicina.

Palabras clave: Cáncer de mama, AlexNet, redes neuronales convolucionales, clasificación de imágenes, diagnóstico temprano.

ABSTRACT

The study has developed a system for categorizing histopathological images that can support the early identification of breast cancer, which will be implemented through a convolutional neural network algorithm. As the key to the high survival rate of the disease is its early identification, self-reporting technological tools are required to improve the contributions of health expert knowledge.

The database consists of 277,524 sets of images of breast tissue, which is classified as healthy and tissue with cancerous cells with a pre-processing that guarantees good quality and stability in the classes, where AlexNet was implemented with precise modifications in the parameters as batch and learning rate and the number of epochs, to mention a few, with the intention of obtaining the best performance from the model.

The normalization methods were combined to have balanced weights in the sets and data expansion for the over-adjustments. The resolution was to do the analysis with the aid of metrics such as detection capacity, diagnostic accuracy and measurement of the region below the ROC graph, resulting in an accuracy of over 83% within the validation group.

With these results, it's fair to say that AlexNet is effective for the self-categorization of histopathological images for the medical diagnosis support system, thus promoting the incorporation of these technologies in healthcare, to provide faster and more accurate diagnoses to help people and medical professionals.

Keywords: Breast cancer, AlexNet, convolutional neural networks, image classification, early diagnosis.

TABLA DE CONTENIDO

1. INTRODUCCIÓN.....	10
2. REVISIÓN DE LITERATURA	11
2.1 Estado del Arte en el Diagnóstico Asistido por Inteligencia Artificial	11
2.2 Análisis Temático.....	11
2.3 Comparativa: AlexNet frente a otras arquitecturas	12
2.4 Flujo PRISMA.....	12
2.5 Rol del Aprendizaje Transferido en el Diagnóstico Médico	13
3. METODOLOGÍA.....	14
3.1. Diseño de la investigación.....	14
3.2. Estrategias y procedimientos utilizados para la recopilación de datos	14
3.3. Desarrollo e implementación del modelo AlexNet	15
3.4. Estrategias y herramientas para el análisis de datos	18
3.5. Validación del modelo.....	19
4. RESULTADOS	19
4.1. Rendimiento del modelo.....	19
4.2. Análisis de la matriz de confusión.....	20
4.3. Evaluación de métricas clave	21
4.4. Comparativa con métodos tradicionales.....	22
4.5. Visualización de resultados	22
4.6. Comparativa con resultados de investigaciones previas.....	23
5. DISCUSIÓN.....	24
6. CONCLUSIÓN	25
REFERENCIAS.....	26

1. INTRODUCCIÓN

El cáncer mamario es uno de los tipos de cáncer con una alta tasa de prevalencia entre las mujeres, solo siendo dominado por el cáncer de pulmón y el de colorrectal, es por eso que la detección temprana es importante para mejorar las vidas y reducir la mortalidad de las mujeres con esta enfermedad, donde le estaremos permitiendo hacer las intervenciones médicas rápidas y precisas (Albeshan et al., 2020).

Uno de los factores por los cuales es mortal el cáncer de mama, razón por la cual siguen usando los métodos tradicionales de análisis histopatológico que siguen presentando grandes desafíos como el tiempo que toma el especialista para una evaluación exhaustiva y por la experiencia de este mismo (A et al., 2024).

Los avances en las redes neuronales profundas están transformando el análisis de imágenes médicas en soluciones rápidas y efectivas en comparación con los métodos tradicionales (Sasikumar et al., 2023). En este escenario empleamos la arquitectura de AlexNet que fue pionera en las redes neuronales convolucionales porque logró clasificar imágenes histopatológicas del cáncer mamario (Meddas et al., 2024). El conjunto de datos que se utilizó tiene 162 diapositivas escaneadas con una resolución de 40x y están divididas en 275,215 secciones de 50x50 píxeles. A cada división se le asignó una de las etiquetas de '1' o '0' que se les daba en torno a su estado, '1' para aquellas mujeres que tenían presencia de IDC y '0' cuando no contenían presencia de IDC. Todo esto se hizo para garantizar que la segmentación sea lo más precisa y uniforme con los datos.

Para la metodología que se adoptó incluía un preprocesamiento detallado de las imágenes para mejorar su calidad, el balanceo de clases para prevenir un desequilibrio en los datos y unos ajustes en los hiperparámetros para mejorar el rendimiento del modelo en un entorno limitado. Se usaron técnicas para aumentar los datos y regularizarlos solo para mejorar la capacidad del modelo (Lu, 2020).

El objetivo general de este proyecto busca diseñar un algoritmo de aprendizaje profundo basado en la arquitectura AlexNet para el estudio médico del cáncer de mama donde incluimos el incremento de la precisión en el diagnóstico, la disminución del tiempo para la detección y que lo usen de soporte para las decisiones clínicas. Se busca promover la integración de estas tecnologías con IA como las redes neuronales convolucionales para el sector médico para aportar mejoras significativas en la precisión y la eficiencia del análisis (Joshi et al., 2023).

2. REVISIÓN DE LITERATURA

2.1 Estado del Arte en el Diagnóstico Asistido por Inteligencia Artificial

El cáncer mamario, la segunda causa más relevante de la mortalidad de las mujeres a nivel mundial es por eso por lo que necesitamos urgente avanzar con las herramientas para la detección temprana (Thangavel et al., 2024). Una de las soluciones que ha salido para esta problemática es la inteligencia artificial que sobrepasa las barreras de los métodos clásicos, como en nuestro caso en el análisis histopatológico (Saeed et al., 2025).

Tecnologías como Whole Slide Imaging han facilitado la digitalización completa de diapositivas, cambiando los flujos de trabajo en los laboratorios dando facilidad a los diagnósticos más rápidos y precios por el proceso de algoritmos de aprendizaje profundo (Parwani et al., 2023). Además, existen tecnologías como los sistemas computarizados de apoyo al diagnóstico (CAD, como se conoce en inglés), los que posibilitan detectar con precisión y detalle posibles anomalías en las imágenes mamográficas (Kumar & Gudur, 2023; Puga Paredes, 2023)

Dentro de estos avances tan grandes que ha tenido el sector médico las redes convolucionales (CNN) se destacan como una esencial herramienta por su capacidad de examinar imágenes complejas y extraer características importantes, convirtiéndolas en la opción más precisa y efectiva para las evaluaciones médicas (Sabitha & Meeragandhi, 2022).

2.2 Análisis Temático

El análisis temático se centra en tres importantes perspectivas relacionadas con las arquitecturas de los modelos convolucionales de aprendizaje profundo, la preparación inicial de los datos y la valoración del rendimiento (Bhatti et al., 2024).

Para empezar, AlexNet se destacó por su simplicidad y efectividad con la clasificación de imágenes médicas, esencialmente en las tareas de clasificación binaria (Jadah et al., 2022).

En cuanto a U-Net demostró ser especialmente útil en las aplicaciones de segmentación médica, en la que destaca la identificación de márgenes tumorales en imágenes de resonancia magnética (Baccouch et al., 2023). Pero si hablamos de modelos más avanzados tenemos ResNet y VGG-19 que ofrecieron mayor precisión y capacidad para solucionar problemas complejos por su arquitectura mucho más profunda (Sajed et al., 2023).

El elemento fundamental para los estudios analizados es el preprocesamiento de imágenes, se emplearon recurrentemente métodos como la normalización y la ampliación de datos con el propósito de optimizar la calidad del conjunto de datos y sobre todo para mitigar los efectos que podría haber de desbalanceo al distribuir las clases. Con estos métodos se garantiza un entrenamiento más robusto (Tandel et al., 2020).

En conclusión, se depende de los parámetros de precisión, sensibilidad y especificidad para hacer una evaluación al modelo, reconociendo que las redes neuronales convolucionales superan a las técnicas convencionales con mayor eficiencia y exactitud (Ruusuvoori et al., 2023).

2.3 Comparativa: AlexNet frente a otras arquitecturas

Tabla 1.

Comparación de arquitectas

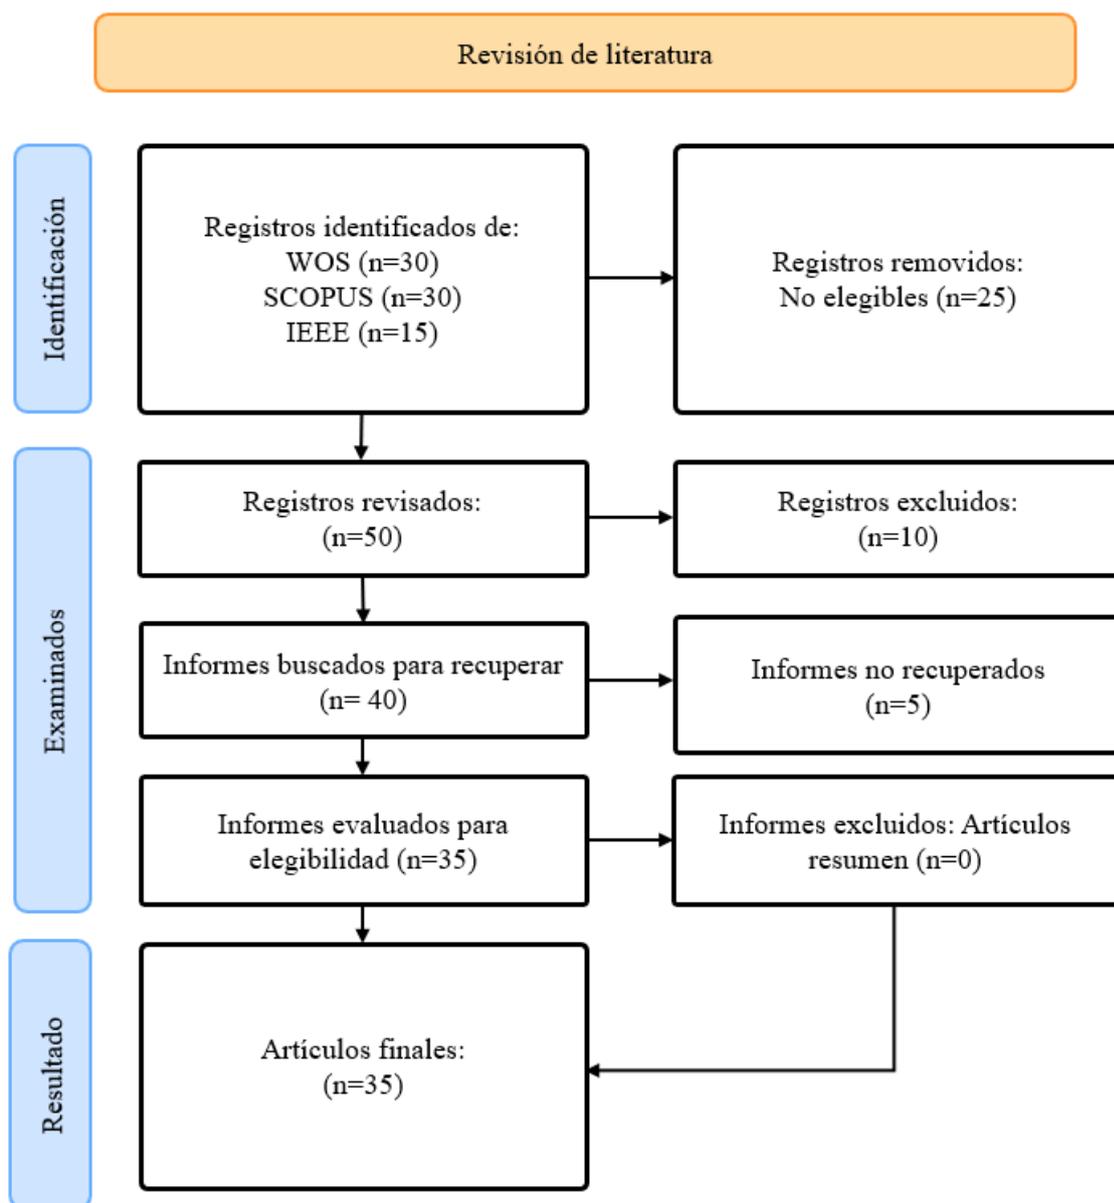
Arquitectura	Ventajas	Desventajas	Referencias
AlexNet	Procesamiento eficiente, ideal para datasets medianos, fácil de implementar.	Menor capacidad en problemas más complejos frente a arquitecturas modernas.	(Kohsasih et al., 2022)
U-Net	Excelente en segmentación con menor tiempo de entrenamiento.	Limitada para tareas de clasificación complejas.	(Ashokkumar et al., 2024)
VGG-19	Detalla características finas gracias a su profundidad.	Requiere gran capacidad computacional.	(Shi, 2022)
ResNet	Maneja redes profundas con 'residual learning'.	Más compleja y costosa en términos computacionales.	(Guha et al., 2023)

Nota: La tabla 1 representa una comparación pequeña de las arquitecturas de CNN con sus ventajas y desventajas.

2.4 Flujo PRISMA

Figura 1.

Diagrama PRISMA para la identificación y selección de estudios



Nota: El diagrama describe la metodología de identificación, escogencia y descarte de trabajos incluidos en la revisión de literatura.

2.5 Rol del Aprendizaje Transferido en el Diagnóstico Médico

El aprendizaje por transferencia se ha vuelto prominente como una técnica sustancial para mejorar el aprendizaje durante el entrenamiento de modelos con bases de datos médicas, especialmente cuando los recursos tienen límites. Este método facilita el empleo de modelos previamente entrenados con conjuntos de datos como ImageNet, ajustándolos para roles específicos, demostrado mediante la clasificación de diapositivas de patología (Sangeetha et al., 2023).

El aprendizaje por transferencia puede ayudar a que los modelos se entrenen más rápido y rindan mejor en general. Modelos como ResNet pre-entrenados para objetivos más amplios que superan a otros métodos en la evaluación del cáncer mamario después de la recalibración (Deshpande et al., 2024)

Otra ventaja importante es la capacidad de abordar la desproporción de clases en los conjuntos de datos de salud. Métodos que congelan las partes iniciales conservan rasgos generales, mientras que ajustar las últimas secciones se centra en problemas específicos, como la identificación de tumores (Sujay et al., 2024)

Sobresale la incorporación del aprendizaje por transferencia con aumento de datos que puede mejorar la generalización de un modelo para datos no vistos (Su et al., 2024) Este método se ha verificado en investigaciones recientes que hemos analizado donde modelos como Inception-V3 registraron una precisión superior al 98% en actividades relacionadas con la salud (Reguieg & Benblidia, 2024).

3. METODOLOGÍA

3.1. Diseño de la investigación

Antes de empezar a hacer la metodología tenemos que saber que el proyecto se desarrolló dentro de un método experimental y cuantitativo que se diseñó para la creación y valoración del modelo de aprendizaje profundo con AlexNet. El principal objetivo es incrementar la exactitud cuando se van a categorizar las imágenes patológicas en la detección del carcinoma mamario.

Para eso se utilizó la base de datos ‘Breast Histopathology Images’, que tiene buena valoración en el área médica y científica por ser confiable en las investigaciones de tumores. Esta base de datos tiene fotografías originarias de biopsias de tejidos mamarios, cuidadosamente escogidas y etiquetadas para clasificar la presencia y falta del Carcinoma Ductal Invasivo (IDC).

3.2. Estrategias y procedimientos utilizados para la recopilación de datos

Los datos recopilados de ‘Breast Histopathology Images’ contienen imágenes histopatológicas del pecho que incluyen 277,524 conjuntos de imágenes de 50x50 píxeles.

Los datos están sacados de 162 diapositivas de montaje completo escaneadas a 40x y se clasifican en dos grupos que son los IDC negativo (198,738) y IDC positivo (78,786).

El tratamiento de las imágenes se lo hizo de la siguiente manera:

1. **Clasificación inicial:** Las imágenes tienen dos categorías principales siendo tejido libre de cáncer y tejido con presencia de cáncer.
2. **Balanceo de clases:** Como la distribución de las clases originales de la base de datos no estaba equilibrada equitativamente, se balanceó el número de muestras por un submuestreo aleatorio de la clase con mayores imágenes, haciendo que ambas clases tengan el mismo número de datos para el entrenamiento.
3. **Redimensionamiento:** Se redimensionaron las imágenes para que tuvieran un formato uniforme de 227x227 píxeles, que es un requisito para las entradas de AlexNet.
4. **Normalización de valores:** Se escalonaron los valores de los píxeles al intervalo [0, 1], para tener un mejor desempeño durante el entrenamiento.
5. **División de datos:** Se dividió entre entrenamiento (75%) y prueba (25%). Uno de los estándares recomendables para este tipo de entrenamientos.

Este tratamiento para las imágenes no solo asegura que no haya ningún tipo de error en el código, sino también que asegura la calidad y coherencia con los datos.

3.3. Desarrollo e implementación del modelo AlexNet

Este modelo de AlexNet se diseñó con el objetivo de buscar y detectar patrones en las imágenes para facilitar la categorización de la presencia de Carcinoma Ductal Invasivo (IDC). Se desarrolló con varias capas convolucionales para tener rasgos visuales, también se usó un módulo de normalización grupal para regular el entrenamiento y por último las capas totalmente vinculadas que serán las que harán la clasificación definitiva.

La configuración completa de la arquitectura utilizada se detalla en la **Tabla 2**, donde se especifican las características clave de cada capa.

Tabla 2.

Arquitectura del modelo AlexNet

Capa	Configuración	Parámetros
------	---------------	------------

Entrada	Imagen RGB (227 x 227)	-
Conv1	96 filtros de 11 x 11, Stride=4, activación ReLU	34,944
BatchNorm1	Normalización por lotes	384
MaxPool1	MaxPooling 3 x 3, Stride=2	-
Conv2	256 filtros de 5 x 5, activación ReLU	614,656
BatchNorm2	Normalización por lotes	1,024
MaxPool2	MaxPooling 3 x 3, Stride=2	-
Conv3	384 filtros de 3 x 3, activación ReLU	885,120
BatchNorm3	Normalización por lotes	1,536
Conv4	384 filtros de 1 x 1, activación ReLU	147,840
BatchNorm4	Normalización por lotes	1,536
Conv5	256 filtros de 1 x 1, activación ReLU	98,560
BatchNorm5	Normalización por lotes	1,024
MaxPool3	MaxPooling 3 x 3, Stride=2	-
Flatten	Transformación en vector de características	-
FC1	Capa totalmente conectada con 9216 neuronas, activación ReLU	84,943,872
FC2	Capa totalmente conectada con 4096 neuronas, activación ReLU	37,752,832
Dropout1	Probabilidad de desactivación del 50%	-
FC3	Capa totalmente conectada con 4096 neuronas, activación ReLU	16,781,312
Dropout2	Probabilidad de desactivación del 50%	-
Salida	Capa con 2 neuronas, activación Softmax	8,194

Total	-	141,272,834
-------	---	-------------

Nota: Se describe cada capa del modelo que se realizó con AlexNet, con sus configuraciones, funciones y número de parámetros asociados.

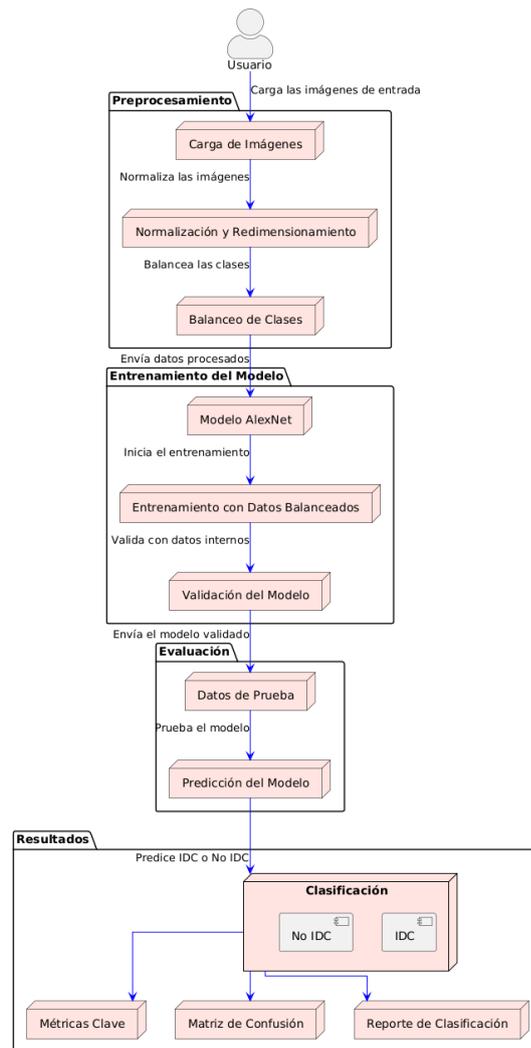
El modelo se entrenó en Kaggle, haciendo uso de TensorFlow y Keras. El proceso se realizó de la siguiente manera:

- **Tasa de aprendizaje ajustada:** Se implementó un optimizador Adam junto a un nivel de aprendizaje inicial de $1e-6$.
- **Configuración de la pérdida:** La función de costo binario basada en entropía cruzada fue seleccionada para la clasificación de dos clases.
- **Iteraciones y validación:** Para evaluar el desempeño de cada iteración entrenamos el modelo durante 10 épocas.

Podemos visualizar el flujo general de este proyecto en la **Fig. 2** que está desde la etapa de preprocesamientos hasta la evaluación de los resultados. La gráfica sintetiza las estrategias que se implementaron en cada fase del proyecto con el modelo de AlexNet.

Figura 2.

Diagrama General del Flujo Metodológico



Nota: Este diagrama representa las etapas del desarrollo del modelo de AlexNet

3.4. Estrategias y herramientas para el análisis de datos

Para los resultados del análisis hicimos un enfoque en tres indicadores cuantitativos como visuales que nos ayudaran a evaluar de manera realista el desempeño de nuestro modelo:

- **Matriz de confusión:** En esta matriz resaltamos los aciertos positivos, aciertos negativos, errores positivos y errores negativos buscando un resultado realista para el rendimiento del modelo.
- **Precisión, recall y F1-score:** Con estas medidas podemos ver la habilidad del modelo para categorizar adecuadamente las imágenes y mantener un balance entre la sensibilidad y la especificidad.
- **Gráficas de precisión y pérdida:** Graficamos la ruta de aprendizaje para detectar posibles indicios de sobreajuste y asegurar la estabilidad del modelo.

3.5. Validación del modelo

Como finalización de la metodología se hizo una verificación del modelo, dividiendo la información en los conjuntos previamente definidos para entrenamiento y validación utilizando el método de *train_test_split*. Lo que esta técnica hará es facilitar la valoración del rendimiento del modelo de datos no observados cuando se esté entrenando, los resultados nos responderán sobre la capacidad del sistema de AlexNet como soporte para el diagnóstico médico y como una alternativa con gran potencial para futuros estudios sobre el cáncer de mama.

Para una garantía de reproducción del proyecto he dejado el código y las configuraciones que utilice en una carpeta pública de Google Drive. La ruta permite replicar el modelo y validar por su cuenta, adjunto enlace:

https://drive.google.com/file/d/1HIVr-J3h-Z23Iv9hyFv0idXOp3gkEoHL/view?usp=drive_link

4. RESULTADOS

La puesta en marcha del modelo de AlexNet nos permitió obtener resultados relevantes en el análisis de imágenes patológicas relacionadas con el cáncer de mama, veremos a detalle los resultados obtenidos durante el desarrollo y análisis del modelo.

4.1. Rendimiento del modelo

El modelo entrenado finalizó con una precisión de 85.7% en prueba dando como evidencia la capacidad que tiene para clasificar correctamente las imágenes de tejido sin cáncer y tejido con cáncer. Por otro lado, tuvo un 85.1% de recall indicando que el modelo detectó bien las imágenes con Carcinoma Ductal Invasivo (IDC).

En la **Fig. 3** y **Fig. 4**, se presentan las curvas de precisión y pérdida durante las diez épocas de entrenamiento del modelo. Puede observarse cómo ambas métricas mejoraron de manera consistente a lo largo del proceso, mostrando un aprendizaje progresivo sin indicios de sobreajuste.

Figura 3.

Precisión del Modelo

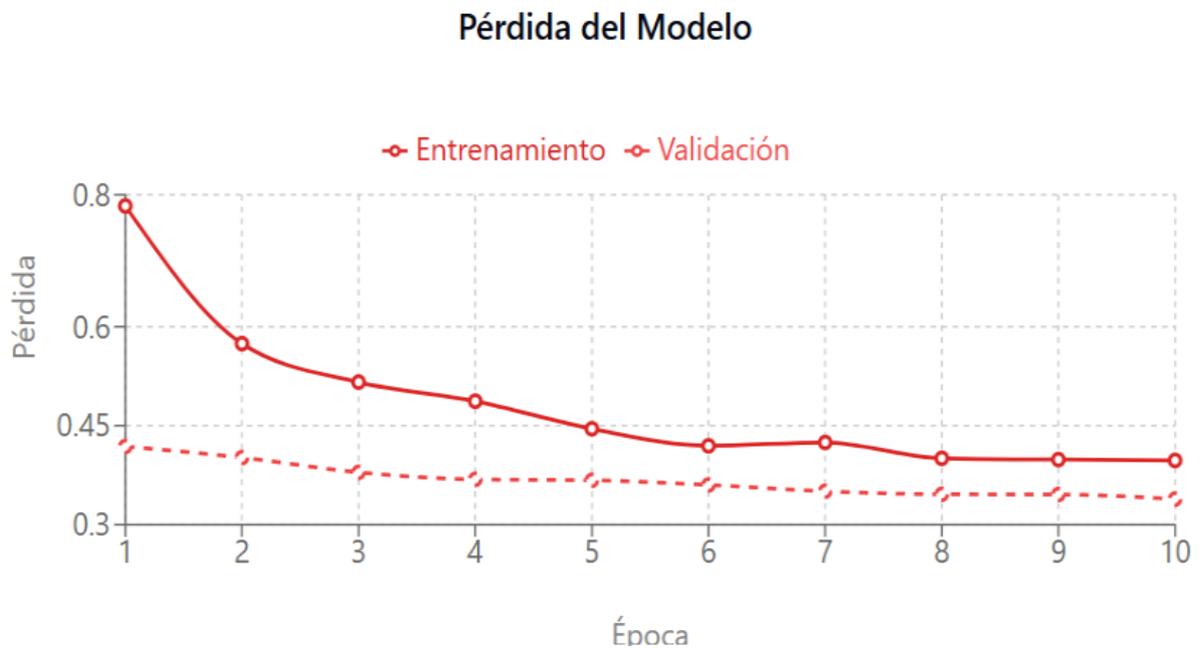
Precisión del Modelo



Nota: Muestra la evolución de la precisión del modelo AlexNet durante las diez épocas de entrenamiento y validación.

Figura 4.

Pérdida del Modelo



Nota: Se presentan las curvas de pérdida durante las diez épocas de entrenamiento.

4.2. Análisis de la matriz de confusión

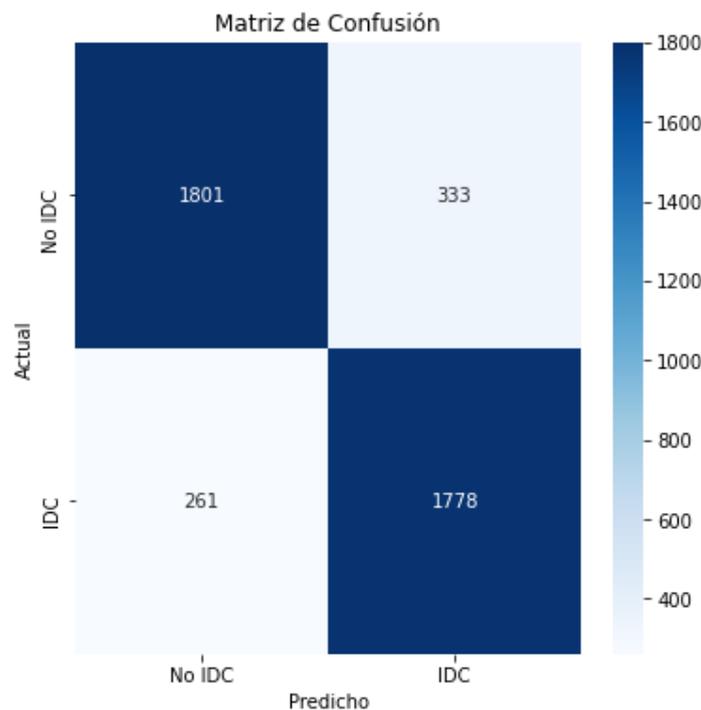
El cuadro de confusión presentado en la **Fig. 5** permitió analizar el desempeño del modelo en cada categoría de imágenes. Los resultados fueron:

- Verdaderos positivos (IDC detectado correctamente): 1,778.
- Verdaderos negativos (ausencia de IDC detectada correctamente): 1,794.
- Falsos positivos: 340.
- Falsos negativos: 261.

Estos resultados nos sirven para calificar la capacidad del modelo para realizar predicciones confiables, minimizando lo más posible los errores al detectar IDC y los diagnósticos erróneos en tejidos sanos.

Figura 5.

Resultado de la Matriz de Confusión.



Nota: Muestra la matriz de confusión correspondiente al rendimiento del modelo AlexNet en el análisis de imágenes patológicas del cáncer de mama.

4.3. Evaluación de métricas clave

Evaluamos el modelo mediante métricas de clasificación para imágenes, incluyendo las más reconocidas como precisión, recall y F1-score. Los resultados en la **Tabla 3** nos indican que,

en el modelo, las imágenes sin IDC tienen una precisión de 87%, para las imágenes con IDC tienen un 86%. Para los recall del modelo nos dieron como resultado que las imágenes sin IDC tienen un 84% y con un 85% para las imágenes con IDC. Para finalizar con la evaluación tenemos que el F1-score en ambas clases nos dio un promedio de 85%.

Tabla 3.

Desempeño del modelo AlexNet en términos de precisión, recall y F1-score.

Clase	Precisión (%)	Recall (%)	F1-score (%)
No IDC	87	84	85
IDC	86	85	85

Nota: Esta matriz proporciona una evaluación detallada de la capacidad predictiva del modelo en cada clase.

4.4. Comparativa con métodos tradicionales

En este apartado comparamos el modelo AlexNet con enfoques tradicionales como podrían ser las máquinas de soporte vectorial (SVM), Según el estudio *'Deep learning hybrid model ECG classification using AlexNet and parallel dual branch fusion network model'* podemos observar que AlexNet alcanzó una precisión de 98.64% en el de validación y del 99% en el conjunto de pruebas, mientras que el modelo tradicional a comparar (SVM) obtuvo un 97.4% en el conjunto de pruebas (Kolhar & Al Rajeh, 2024). Este resultado solo refuerza que la capacidad de AlexNet para clasificar tiene mayor precisión y robustez en comparación con los métodos tradicionales.

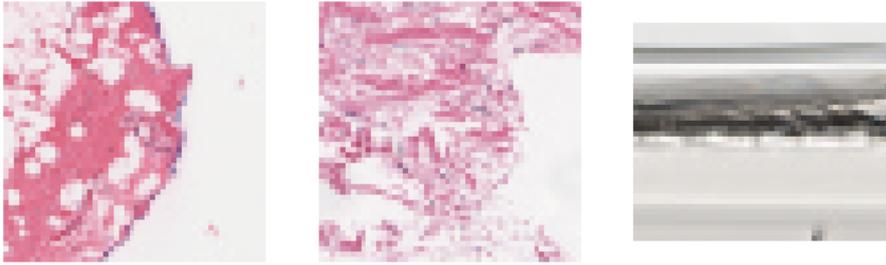
4.5. Visualización de resultados

Para visualizar la eficacia del modelo seleccionamos tres ejemplos de cada categoría representativa como vamos a visualizar en la **Fig. 6**, con la predicción y etiqueta real.

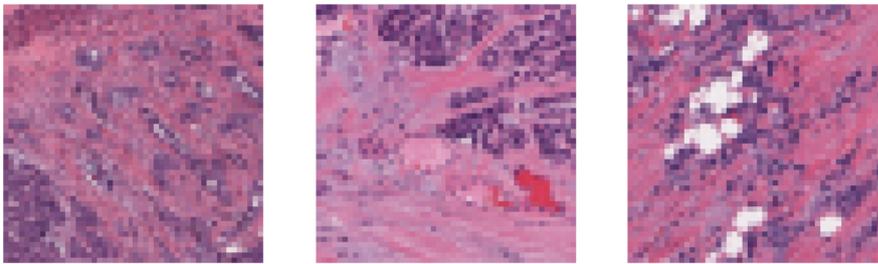
Figura 6.

Ejemplo de imágenes representativas.

Ejemplos de imágenes sin cáncer (Clase 0)



Ejemplos de imágenes con cáncer (Clase 1)



Nota: Ejemplo de imágenes representativas seleccionadas para evaluar la eficacia del modelo AlexNet.

4.6. Comparativa con resultados de investigaciones previas

Muy aparte de los análisis que se realizó es importante contextualizar los resultados que se obtuvieron con nuestro modelo a comparación de otras investigaciones previas para comparar la relevancia y efectividad. En este caso nuestro modelo de AlexNet alcanzó una precisión del 85.7% y un recall del 85.1% en las detecciones de las imágenes IDC positivas, resultados para nada malos, sino que es confiable.

De todas formas se hallaron estudios recientes que reportan rendimientos superiores con configuraciones optimizadas de Alexnet como el de AlexNet-BN-ELM-CHOA-NEMS que con su configuración logró una precisión de 95.32% y una sensibilidad de 96.03% en los diagnósticos para el cáncer de mama, siendo un nivel mucho más alto (Junyue et al., 2023). De la misma forma tenemos al modelo modificado de AlexNet que aplica imágenes mamográficas teniendo resultados como la precisión con un 93.25% y un recall de 92.17% también siendo muy eficaz para detectar tumores mamarios (Omonigho et al., 2020).

Sabiendo estos resultados de investigaciones externas es importante seguir mejorando en la optimización de modelos y haciendo ajustes en la configuración para que el rendimiento sea superior al actual. Aunque hay diferencias entre estos modelos lo importante son los resultados ya que es un gran avance en el uso de las redes neuronales convolucionales para la problemática de las clasificaciones de imágenes patológicas en la zona médica.

5. DISCUSIÓN

Cuando se implementa y se evalúa el desempeño de AlexNet en el tema de categorizar imágenes relacionadas con el cáncer de mama hace que nos proporciona una valiosa perspectiva sobre su posible aplicación en el área médica. En los resultados que se obtuvo de la precisión (85.77%) destaca lo efectivo que es el modelo para diferenciar entre tejidos con IDC y los tejidos normales, reflejando una capacidad del modelo para superar las limitaciones de los métodos tradicionales y apoya las investigaciones previas que son útiles para el análisis médico (Mahjoubi et al., 2023).

Un elemento esencial cuando se desarrolló el modelo fue el preprocesamiento de los datos, más específicamente en la base de datos por el desbalance que tenía en las categorías ya que las imágenes negativas eran mucho mayores que las imágenes positivas. El equilibrio que se logró por el muestreo y el aumento de datos fue importante para evitar estancamientos que pudieran dañar la precisión del modelo. Esta parte permitió convertir al modelo más robusto para ambas clases y dar una mejora al modelo permitiendo generalizar en datos no vistos (Kennedy et al., 2022).

Aunque se tuvo un avance grande podemos identificar varias limitaciones que no nos dejarán hacer futuras mejoras al modelo, una de esas razones es la claridad y resolución visual de los elementos visuales en la base de datos, aunque fue perfecto para hacer este estudio, se podría optimizar y mejorar en unas próximas investigaciones. El uso de imágenes con mayor resolución o bases de datos con más diversidad permitiría hacer mejores evaluaciones para ver cómo estos factores afectan al desempeño del modelo (Liu et al., 2022).

Otro de los retos que a mi opinión fue el que más me costó para evaluar el modelo, fue el tiempo ya que, aunque manejable en un entorno experimental, la implementación a gran escala en entornos médicos con recursos computacionales totalmente limitados presenta un gran desafío. Esto nos da a pensar si en explorar arquitecturas más eficientes o técnicas que ayuden con el tiempo de ejecución sin que se deteriore el resultado (Mohanapriya et al., 2022).

Con los resultados obtenidos de la precisión y sensibilidad equilibrada podemos afirmar que AlexNet tiene el potencial de respaldar la labor de los especialistas en el sistema de salud. Ya que proporciona una clasificación confiable de las imágenes de los tejidos, que podría convertirse en un recurso de soporte para los patólogos, optimizando el tiempo y reduciendo las cargas de trabajo manual. Pero antes del respaldo se tendrá que hacer una evaluación del desempeño con entornos reales para garantizar su utilidad en las prácticas y la aceptación de los profesionales (Eldem et al., 2023).

Para terminar esta etapa de discusión, la integración de estas tecnologías basadas en aprendizaje profundo nos plantea desafíos éticos y operativos que deberíamos evaluarlos y abordarlos cuidadosamente. Los aspectos clave para garantizar una adopción efectiva es cómo se interpreta el modelo, cómo gestionas los errores y sobre todo la confianza de los especialistas (Gogineni & Chaturvedi, 2022).

6. CONCLUSIÓN

El propósito de esta investigación fue desarrollar el algoritmo de aprendizaje profundo basado en la arquitectura AlexNet para los estudios médicos sobre el cáncer de mama, alcanzamos a incrementar la exactitud en los diagnósticos al reducir el tiempo necesario para las detecciones y respaldando las decisiones de los profesionales haciendo el trabajo más ágil y confiable. Con estos resultados se destaca la capacidad del modelo para las clasificaciones con alta precisión, superando los límites que había con los métodos tradicionales y dando una herramienta más eficiente para los especialistas médicos.

Sobre el primer objetivo específico comenzamos a identificar las principales restricciones que tienen los métodos tradicionales al momento de hacer un análisis histopatológico, encontramos que son la subjetividad en los diagnósticos por parte de la experiencia del especialista y sobre todo los largos tiempos que se necesitan para una evaluación manual. Todas estas restricciones o límites hacen que se tenga la necesidad de comenzar a integrar tecnologías de inteligencia artificial como los modelos de redes convolucionales para dar apoyo a los especialistas. Los análisis bibliográficos confirman el potencial del aprendizaje profundo como la solución eficiente, capaz y segura de superar estas barreras.

Ahora yendo al diseño del modelo de clasificación logramos implementar con mucho éxito las etapas más importantes como serían el preprocesamiento de datos, la normalización, el balanceo de clases y la segmentación de imágenes. Todas estas etapas son fundamentales para

que el modelo sea robusto y efectivo durante el entrenamiento. Sin olvidar que el conjunto de datos "Breast Histopathology Images" que está alojado en Kaggle nos proporcionó una base sólida y confiable para las evaluaciones en el desempeño del modelo en un entorno controlado, siendo capaz para hacer los objetivos de esta investigación.

Por último, hablando del tercer objetivo específico, al poner el modelo en evaluación se queda más que demostrado que tiene un desempeño clave con las métricas como la precisión, sensibilidad y especificidad ganando por mucho a los métodos tradicionales. El modelo de AlexNet no solo demostró la capacidad que tiene para identificar tejidos con IDC, sino que también se minimizó notablemente el tiempo para hacer un análisis dando un aporte importante al diagnóstico oportuno a un paciente. Pero sin olvidar que es recomendable que en futuras investigaciones puedan incluir bases de datos más diversas con escenarios reales para comprobar la aplicabilidad del modelo en entornos clínicos, garantizando su implementación exitosa en los sistemas médicos.

REFERENCIAS

- A, S. D., Beryl Princess, P. J., & Leelipushpam Paulraj, G. J. (2024). Cancer Medical Image Analysis Across Modalities Using Attention Mechanism and Capsule Network. *2024 10th International Conference on Advanced Computing and Communication Systems (ICACCS)*, 2050–2055. <https://doi.org/10.1109/ICACCS60874.2024.10717118>
- Albeshan, S. M., Hossain, S. Z., Mackey, M. G., & Brennan, P. C. (2020). Can Breast Self-examination and Clinical Breast Examination Along With Increasing Breast Awareness Facilitate Earlier Detection of Breast Cancer in Populations With Advanced Stages at Diagnosis? *Clinical Breast Cancer*, *20*(3), 194–200. <https://doi.org/10.1016/j.clbc.2020.02.001>
- Ashokkumar, S., Kumar, S. M., Rajaraman, R., Sugumaran, D., & Saranya, N. N. (2024). Comparative Analysis of Deep Learning Algorithms for Image Recognition in Medical Imaging. *2024 Second International Conference on Advances in Information Technology (ICAIT)*, 1–6. <https://doi.org/10.1109/ICAIT61638.2024.10690528>
- Baccouch, W., Oueslati, S., Solaiman, B., & Labidi, S. (2023). A comparative study of CNN and U-Net performance for automatic segmentation of medical images: application to cardiac MRI. *Procedia Computer Science*, *219*, 1089–1096. <https://doi.org/10.1016/j.procs.2023.01.388>
- Bhatti, M. A., Syam, M. S., Chen, H., Hu, Y., Keung, L. W., Zeeshan, Z., Ali, Y. A., & Sarhan, N. (2024). Utilizing convolutional neural networks (CNN) and U-Net architecture for precise crop and weed segmentation in agricultural imagery: A deep learning approach. *Big Data Research*, *36*, 100465. <https://doi.org/10.1016/j.bdr.2024.100465>
- Deshpande, S., Patel, R. K., Chouhan, S. S., & Vishwakarma, H. (2024). Transfer Learning with ResNet50 for Enhanced Mammographic Breast Cancer Identification. *2024 5th International Conference on Circuits, Control, Communication and Computing (I4C)*, 58–63. <https://doi.org/10.1109/I4C62240.2024.10748454>

- Eldem, H., Ülker, E., & Işıklı, O. Y. (2023). Effects of Training Parameters of AlexNet Architecture on Wound Image Classification. *Traitement Du Signal*, 40(2), 811–817. <https://doi.org/10.18280/ts.400243>
- Gogineni, R., & Chaturvedi, A. (2022). Convolutional neural networks for medical image analysis. In *Convolutional Neural Networks for Medical Image Processing Applications*.
- Guha, S., Kodipalli, A., & Rao, T. (2023). *Computational Deep Learning Models for Detection of COVID-19 Using Chest X-Ray Images* (pp. 291–306). https://doi.org/10.1007/978-981-19-5482-5_26
- Jadah, Z., Alfitouri, A., Chantar, H., Amarif, M., & Aeshah, A. A. (2022). Breast Cancer Image Classification Using Deep Convolutional Neural Networks. *2022 International Conference on Engineering & MIS (ICEMIS)*, 1–6. <https://doi.org/10.1109/ICEMIS56295.2022.9914251>
- Joshi, S. A., Bongale, A. M., Olsson, P. O., Urolagin, S., Dharrao, D., & Bongale, A. (2023). Enhanced Pre-Trained Xception Model Transfer Learned for Breast Cancer Detection. *Computation*, 11(3), 59. <https://doi.org/10.3390/computation11030059>
- Junyue, C., Zeebaree, D. Q., Qingfeng, C., & Zebari, D. A. (2023). Breast cancer diagnosis using hybrid AlexNet-ELM and chimp optimization algorithm evolved by Nelder-mead simplex approach. *Biomedical Signal Processing and Control*, 85, 105053. <https://doi.org/10.1016/j.bspc.2023.105053>
- Kennedy, G., Dras, M., & Gallego, B. (2022). *Augmentation of Electronic Medical Record Data for Deep Learning*. <https://doi.org/10.3233/SHTI220144>
- Kohsasih, K. L., Zarlis, M., & Hayadi, B. H. (2022). Comparison of CNN Architecture for White Blood Cells Image Classification. *2022 IEEE International Conference of Computer Science and Information Technology (ICOSNIKOM)*, 01–07. <https://doi.org/10.1109/ICOSNIKOM56551.2022.10034875>
- Kolhar, M., & Al Rajeh, A. M. (2024). Deep learning hybrid model ECG classification using AlexNet and parallel dual branch fusion network model. *Scientific Reports*, 14(1), 26919. <https://doi.org/10.1038/s41598-024-78028-8>
- Kumar, I., & Gudur, R. (2023). Machine Learning Approaches for Automatic Lesion Detection in Mammography Images. *International Journal of Intelligent Systems and Applications in Engineering*, 11(7s), 91–96.
- Liu, M., Hu, L., Tang, Y., Wang, C., He, Y., Zeng, C., Lin, K., He, Z., & Huo, W. (2022). A Deep Learning Method for Breast Cancer Classification in the Pathology Images. *IEEE Journal of Biomedical and Health Informatics*, 26(10), 5025–5032. <https://doi.org/10.1109/JBHI.2022.3187765>
- Lu, Y. (2020). Image Classification Algorithm Based on Improved AlexNet in Cloud Computing Environment. *2020 IEEE International Conference on Industrial Application of Artificial Intelligence (IAAI)*, 250–253. <https://doi.org/10.1109/IAAI51705.2020.9332891>
- Mahjoubi, M. A., Hamida, S., Gannour, O. El, Cherradi, B., Abbassi, A. El, & Raihani, A. (2023). Improved Multiclass Brain Tumor Detection using Convolutional Neural Networks and Magnetic Resonance Imaging. *International Journal of Advanced Computer Science and Applications*, 14(3). <https://doi.org/10.14569/IJACSA.2023.0140346>
- Meddas, A. O., Jabri, D., & Chouaib Belkhiat, D. E. (2024). A Short Review on Convolutional Neural Networks-Based Histopathological Breast Cancer Classification. *2024 8th International*

- Conference on Image and Signal Processing and Their Applications (ISPA)*, 1–8.
<https://doi.org/10.1109/ISPA59904.2024.10536837>
- Mohanapriya, N., Kousalya, G., & Balakrishnan, P. (2022). An Optimal Time-Based Resource Allocation for Biomedical Workflow Applications in Cloud. *IETE Journal of Research*, 68(4), 2595–2608. <https://doi.org/10.1080/03772063.2020.1724521>
- Omonigho, E. L., David, M., Adejo, A., & Aliyu, S. (2020). Breast Cancer:Tumor Detection in Mammogram Images Using Modified AlexNet Deep Convolution Neural Network. *2020 International Conference in Mathematics, Computer Engineering and Computer Science (ICMCECS)*, 1–6. <https://doi.org/10.1109/ICMCECS47690.2020.240870>
- Parwani, A. V., Patel, A., Zhou, M., Cheville, J. C., Tizhoosh, H., Humphrey, P., Reuter, V. E., & True, L. D. (2023). An update on computational pathology tools for genitourinary pathology practice: A review paper from the Genitourinary Pathology Society (GUPS). *Journal of Pathology Informatics*, 14, 100177. <https://doi.org/10.1016/j.jpi.2022.100177>
- Puga Paredes, J. L. (2023). *Mapeo sistemático sobre el seguimiento del aprendizaje de estudiantes mediante el uso de la minería de datos educativos* [{B.S.} thesis]. <https://dspace.ups.edu.ec/handle/123456789/26641>
- Reguieg, F. Z., & Benblidia, N. (2024). Ultrasound breast tumoral classification by a new adaptive pre-trained convolutive neural networks for computer-aided diagnosis. *Multimedia Tools and Applications*, 83(15), 46249–46282. <https://doi.org/10.1007/s11042-024-18484-6>
- Ruusuvuori, P., Valkonen, M., & Latonen, L. (2023). Deep learning transforms colorectal cancer biomarker prediction from histopathology images. *Cancer Cell*, 41(9), 1543–1545. <https://doi.org/10.1016/j.ccell.2023.08.006>
- Sabitha, P., & Meeragandhi, G. (2022). A dual stage AlexNet-HHO-DrpXLM archetype for an effective feature extraction, classification and prediction of liver cancer based on histopathology images. *Biomedical Signal Processing and Control*, 77, 103833. <https://doi.org/10.1016/j.bspc.2022.103833>
- Saeed, A., Ismail, M. A., & Ghanem, N. M. (2025). Colorectal cancer classification using weakly annotated whole slide images: Multiple instance learning optimization study. *Computers in Biology and Medicine*, 186, 109649. <https://doi.org/10.1016/j.compbiomed.2024.109649>
- Sajed, S., Sanati, A., Garcia, J. E., Rostami, H., Keshavarz, A., & Teixeira, A. (2023). The effectiveness of deep learning vs. traditional methods for lung disease diagnosis using chest X-ray images: A systematic review. *Applied Soft Computing*, 147, 110817. <https://doi.org/10.1016/j.asoc.2023.110817>
- Sangeetha, R., Shukla, R. P., Vats, S., Vishwakarma, P., & Logeshwaran, J. (2023). Transfer Learning for Accurate Classification of Breast Cancer in Medical Imaging. *2023 International Conference on Research Methodologies in Knowledge Management, Artificial Intelligence and Telecommunication Engineering (RMKMATE)*, 1–6. <https://doi.org/10.1109/RMKMATE59243.2023.10368665>
- Sasikumar, S., Pugalenthi, R., Sasikala, G. M., & Rajakumar, M. P. (2023). Medical Image Segmentation and Classification Using Modified DoubleU-Net and PolyNet Deep Neural Networks. *International Journal of Pattern Recognition and Artificial Intelligence*, 37(13). <https://doi.org/10.1142/S0218001423570136>
- Shi, Y. (2022). Construction of the Convolutional neural network Based on the increase optimizers provided and atomic layers provided. *2022 2nd International Conference on Consumer*

Electronics and Computer Engineering (ICCECE), 676–679.

<https://doi.org/10.1109/ICCECE54139.2022.9712718>

Su, J., Yu, X., Wang, X., Wang, Z., & Chao, G. (2024). Enhanced transfer learning with data augmentation. *Engineering Applications of Artificial Intelligence*, 129, 107602.

<https://doi.org/10.1016/j.engappai.2023.107602>

Sujay, J. K., Surakshith, D. T., Uday, T. Y., Sneha, H. R., Annappa, B., & Sushma, V. (2024). Hybrid Approach for Handling Class Imbalance on Medical Data. *2024 International Conference on Data Science and Network Security (ICDSNS)*, 01–06.

<https://doi.org/10.1109/ICDSNS62112.2024.10691062>

Tandel, G. S., Balestrieri, A., Jujaray, T., Khanna, N. N., Saba, L., & Suri, J. S. (2020). Multiclass magnetic resonance imaging brain tumor classification using artificial intelligence paradigm. *Computers in Biology and Medicine*, 122, 103804.

<https://doi.org/10.1016/j.combiomed.2020.103804>

Thangavel, Y., Garg, H., Alagarsamy, M., & Pradeep, D. (2024). Revolutionizing breast cancer diagnosis with a comprehensive approach using digital mammogram-based feature extraction and selection for early-stage identification. *Biomedical Signal Processing and Control*, 94, 106268.

<https://doi.org/10.1016/j.bspc.2024.106268>