

UNIVERSIDAD AUTÓNOMA DE BUCARAMANGA
FACULTAD DE INGENIERÍA
INGENIERÍA BIOMÉDICA

Desarrollo de un sistema para la detección y clasificación de artefactos asociados a las imágenes mamográficas.

Presentado por:

Diego Andres Ariza Carrillo
Jennifer Andrea Martinez Malaver

Código:

U00113797

U00113969

Director:

Ing. Manuel Hernando Franco Arias

Codirector:

Ing. Angela Patricia Morales Salcedo

Bucaramanga

2022

Dedicatoria

La presente tesis está dedicada en primera instancia a Dios, ya que gracias a Él he logrado concluir mi carrera, a mis padres Nelson Alfonso Martínez Aragón, Jorge Alexander Rodríguez, a mi madre Nohelia Malaver Rojas y a mi hermana Leidy Johanna Martínez Malaver por brindarme el apoyo para cumplir mis metas, proyectos y sueños, además de forjarme con valores, principios y darme todas las herramientas para afrontar cualquier situación. Este logro es de todos ustedes.

- *Jennifer Andrea Martínez Malaver.*

Dedicatoria

El presente proyecto de investigación está dedicado primeramente a Dios por bendecirme y llenarme de sabiduría para realizar con éxito el presente trabajo de tesis, a mis padres Alexanders Ariza y Yina P. Anichiarico por apoyarme en todo momento, por sus consejos, valores, inculcando en mí principios de perseverancia y constancia; por su motivación constante que me han permitido ser una persona de bien, gracias a su amor y educación en todo momento.

- *Diego Andrés Ariza Carrillo*

Agradecimientos

Todo el agradecimiento sea para Dios, por dar las herramientas para cumplir con esta meta, a nuestros padres Alexanders Ariza, Yina P. Carrillo, Nohelia Malaver, Jorge A. Rodríguez y familia por entregar todo su apoyo durante el proceso de aprendizaje, dar ánimo y fortaleza para culminar con excelencia el proceso de aprendizaje; a los directores de tesis Manuel Franco, y Angela Morales, cuerpo docente y director del programa de Ingeniería Biomédica de la Universidad Autónoma de Bucaramanga por brindar y compartir sus conocimientos, consejos y guianzas que fueron las herramientas bases para lograr el presente proyecto final; a todos los amigos y compañeros que conocí durante la trayectoria de aprendizaje por brindarnos el apoyo incondicional para crecer profesionalmente.

Resumen

La mamografía es un método basado en el uso de equipos emisores de Rayos X y que es ampliamente implementado en la actualidad por profesionales de la salud y grupos de investigación, con el fin de realizar un diagnóstico acertado de patologías en la mama. Estos diagnósticos frecuentemente se ven afectados debido a la presencia de artefactos en las imágenes mamográficas, ocasionando confusión, falsos positivos y/o retraso en los tratamientos de los pacientes. Por lo tanto, se desarrolló un sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas haciendo uso de técnicas de procesamiento de imágenes e inteligencia artificial en el software Python y utilizando librerías como OpenCV, PysimpleGUI, Tensor Flow, entre otras.

El entrenamiento del sistema se consiguió gracias a la implementación de distintas técnicas de procesamiento de imágenes, tales como binarización, ajuste de contraste, dilatación, entre otras, con imágenes mamográficas en formato DICOM, dando como resultado imágenes más sencillas de estudiar para proceder a usar un clasificador basado en redes neuronales convolucionales. Una vez finalizado el entrenamiento se ejecutan pruebas de funcionamiento con un tamaño de muestra de 45 imágenes para cada grupo de estudio, es decir, para imágenes con artefacto de *Contrast Splatter*, pixel blanco, líneas radiolúcidas o sin artefactos, con el propósito de determinar la eficiencia del software. Los resultados obtenidos de las pruebas de funcionamiento permiten concluir el correcto desempeño del software a la hora de clasificar artefactos. Estos resultados posibilitan la validación del funcionamiento de la aplicación.

Abstract

Mammography is a method based on the use of X-Ray emitting equipment that is widely implemented nowadays by health professionals and research groups in order to make an accurate diagnoses of breast pathologies. These diagnoses are frequently affected due to the presence of artifacts in the mammographic images, causing confusion, false positives and/or a delay in the treatment of patients. Therefore, a system for detection and classification of artifacts associated with mammographic images was designed using image processing, and artificial intelligence techniques in Python software and using libraries such as OpenCV, PysimpleGUI, Tensor Flow.

The training of the system was achieved thanks to the implementation of different image processing techniques, such as binarization, contrast adjustment, dilation, with mammographic images in DICOM format, resulting in simpler images to study in order to proceed to use a classifier based on convolutional neural networks. Once the training is finished, performance tests are executed with a sample size of 45 images for each study group, that is, for images with the artifacts: Contrast Splatter, white pixel, radiolucent lines or without artifacts, in order to determine the efficiency of the software. The results obtained from the functional tests allow concluding the correct performance of the software when classifying artifacts. These results make it possible to validate the application's performance.

Índice

Capítulo I	13
Aspectos generales	13
1.1 Problema u Oportunidad.	13
1.2 Descripción del problema	15
1.3 Justificación	17
1.4 Pregunta problema	18
1.5 Objetivo general	18
1.6 Objetivos específicos	18
1.7 Limitaciones y Delimitaciones	19
Capítulo II	20
Marco Teórico y Estado del Arte	20
2.1 Marco teórico	20
2.1.1 Artefacto	20
2.1.2 Mamografía.	20
2.1.3 Procesamiento de imágenes	21
2.1.4 Mamógrafo.	22
2.1.5 Imagen digital.	22
2.1.6 Segmentación.	23
2.2 Estado del Arte	24
2.3 Trayecto Histórico	31
2.4 Marco legal e implicaciones éticas.	32
Metodología	34
3.1 Consulta de las técnicas de procesamiento de imágenes e inteligencia artificial.	35
3.2 Contrastar las técnicas de procesamiento de imágenes e inteligencia artificial.	36
3.3 Selección de la técnica de procesamiento de imágenes e inteligencia artificial.	36
3.4 Diagrama de flujo.	37
3.5 Diseño algoritmo de detección y clasificación de artefactos.	38
3.6 Diseño de interfaz.	39
3.7 Descripción de las pruebas de funcionamiento.	39
3.8 Pruebas de software.	40
3.9 Análisis estadístico	41
Capítulo IV	42
Resultados obtenidos.	42

4.1 Consultar diferentes técnicas de procesamiento de imágenes e inteligencia artificial.	42
4.2 Comparación de las técnicas de procesamiento de imágenes e inteligencia artificial.	43
4.3 Selección de las técnicas.	49
4.4 Diagrama de flujo.	52
4.5 Software de Aplicación	53
4.5.1 Procesamiento de imágenes.	54
4.5.2 Algoritmo implementado.	56
4.5.3 Diseño de la interfaz.	64
4.6 Pruebas de funcionamiento del sistema.	74
4.7 Pruebas de funcionamiento del sistema de clasificación.	75
4.8 Análisis estadístico.	85
Capítulo V	89
Análisis de resultados	89
5.1 Análisis de resultados de la investigación de las diferentes técnicas de procesamiento de imagen e inteligencia artificial.	89
5.2 Análisis de resultados de la comparación de las técnicas de procesamiento de imágenes e inteligencia artificial.	89
5.3 Selección de las técnicas.	90
5.4 Análisis de resultados de diagrama de flujo.	91
5.5 Análisis de resultados de procesamiento de imágenes.	91
5.6 Análisis de resultados de algoritmo implementado.	91
5.7 Análisis de resultados de Diseño de la interfaz.	92
5.8 Análisis de resultados de pruebas de funcionamiento del sistema.	93
5.9 Análisis de resultados estadísticos.	94
Capítulo VI	96
Conclusiones y recomendaciones	96
6.1 Conclusiones.	96
6.2 Recomendaciones	97
Capítulo VII	98
Bibliografía	98

Contenido de Figuras

Figura 1. Mamografía: El mejor método para la detección precoz del cáncer de mama.	21
Figura 2. Mamógrafo MX-600.	22
Figura 3. Modelo de clasificación basado en R-CNN.	25
Figura 4. Diagrama de bloques de la metodología aplicada.	34
Figura 5. Diagrama de flujo de la metodología aplicada.	53
Figura 6. a) Imagen original con artefacto <i>contrast splatter</i> , b) Imagen del artefacto <i>contrast splatter</i> con ajuste de contraste, c) Imagen con artefacto <i>contrast splatter</i> binarizada.	54
Figura 7. a) Imagen original con artefacto <i>pixel blanco</i> , b) Imagen del artefacto <i>pixel blanco</i> cambiando el color de los pixeles blancos a negros y los pixeles color negros a blanco, c) Imagen con artefacto <i>pixel blanco</i> implementando filtro de dilatación.	55
Figura 8. a) Imagen original con artefacto <i>línea radiolúcida</i> , b) Imagen del artefacto <i>línea radiolúcida</i> ajustando el contraste, c) Imagen con artefacto <i>línea radiolúcida</i> implementando filtro gaussiano, d) Imagen del artefacto <i>línea radiolúcida</i> restando la imagen con el filtro gaussiano [c] con la imagen original [a].	56
Figura 9. Organización del algoritmo.	57
Figura 10. Resultados de las imágenes correspondientes a los artefactos de Contrast splatter.	59
Figura 11. Resultados de las imágenes correspondientes a los artefactos de Contrast splatter después de realizar el cambio en las características.	60
Figura 12. Resultados de las imágenes correspondientes a los artefactos de línea radiolúcida.	60
Figura 13. Resultados de las imágenes correspondientes a los artefactos de línea radiolúcida después de realizar el cambio en las características.	61
Figura 14. Matriz de confusión del entrenamiento y clasificación generado por la red neuronal de predicción del artefacto de Contrast splatter.	63
Figura 15. Matriz de confusión del entrenamiento y clasificación generado por la red neuronal de predicción del artefacto de Líneas verticales.	63
Figura 16. Ventana de inicio del “sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	64
Figura 17. Logotipo del software “ Sistema para la detección y clasificación de artefactos asociados a las imágenes mamográficas”.	65
Figura 18. Ventana principal del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”..	66
Figura 19. Ventana de búsqueda de imágenes para entrenar el “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	66
Figura 20. Ubicación del archivo en la barra de búsqueda del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	67

Figura 21. Visualización de la imagen original del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	67
Figura 22. Visualización de la imagen con el artefacto clasificado del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	68
Figura 23. Visualización de la imagen binaria con el artefacto clasificado del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	69
Figura 24. Visualización de la imagen binaria con el artefacto clasificado del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	69
Figura 25. Visualización de la imagen binaria con el artefacto clasificado del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	70
Figura 26. Visualización artefacto superpuesto “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	70
Figura 27. Visualización artefacto superpuesto “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	71
Figura 28. Visualización artefacto superpuesto “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	71
Figura 29. Visualización de informe de resultados “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	72
Figura 30. Visualización de informe de resultados “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	72
Figura 31. Reinicio de datos del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	73
Figura 32. Visualización artefacto <i>Contrast Splatter</i> “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	81
Figura 33. Visualización artefacto Pixel blanco “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	82
Figura 34. Visualización artefacto Líneas radiolúcidas “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	82
Figura 35. Visualización artefacto <i>Contrast Splatter</i> superpuesto “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	83
Figura 36. Visualización artefacto Pixel blanco superpuesto “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	83
Figura 37. Visualización artefacto superpuesto “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	84
Figura 38. Visualización artefacto Líneas radiolúcidas superpuesto “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”.	84
Figura 39. Gráfico de cajas resultados de imágenes con artefactos de <i>Contrast Splatter</i> Vs imágenes sin artefactos.	86
Figura 40. Gráfico de cajas resultados de imágenes con artefactos de líneas radiolúcidas Vs imágenes sin artefactos.	87

Figura 41. Gráfico de cajas resultados de imágenes con artefactos de pixel blanco Vs imágenes sin artefactos.	87
Figura 42. a) Tabla de clasificación artefacto de <i>Contrast Splatter</i> con clase 0 y clase 1; b) Tabla de clasificación artefacto de pixel blanco con clase 0 y clase 1.	92

Contenido de Tablas

Tabla 1. Descripción, causa, apariencia y visualización de cada uno de las clasificación es de artefactos que se pueden presentar en imágenes mamográficas.	26-31
Tabla 2. Modelo del formato de tabla resumen de los criterios y conceptos que se escogieron para la selección de las técnicas de procesamiento de imágenes.	36
Tabla 3. Modelo del formato de tabla resumen de los criterios y conceptos que se escogieron para la selección de las técnicas de Inteligencia Artificial	37
Tabla 4. Tabla comparativa de las técnicas de procesamiento de imágenes.	43-46
Tabla 5. Tabla comparativa de las técnicas de inteligencia artificial.	47-49
Tabla 6. Tabla resumen de los criterios y conceptos que se escogieron para la selección de las técnicas de inteligencia artificial.	49
Tabla 7. Tabla de los criterios de selección de las técnicas de inteligencia artificial.	50
Tabla 8. Tabla de los conceptos de selección de las técnicas de inteligencia artificial.	50
Tabla 9. Distribución de cantidad de imágenes implementadas para el entrenamiento de la red neuronal correspondiente a los artefactos de Contrast splatter y de Línea radiolúcida.	61
Tabla 10. Representación de los resultados obtenidos de las características del sistema de detección después de realizar el entrenamiento de la redes neuronales.	62
Tabla 11. Tabla de resultados de funcionamiento del sistema.	73-74
Tabla 12. Tabla de resultados de las pruebas de funcionamiento de detección y clasificación de artefactos <i>Contrast Splatter</i> .	75-76
Tabla 13. Tabla de resultados de las pruebas de funcionamiento de detección y clasificación de artefactos pixel blanco.	76-77
Tabla 14. Tabla de resultados de las pruebas de funcionamiento de detección y clasificación de artefactos línea radiolúcida.	78-79
Tabla 15. Tabla de resultados de las pruebas de funcionamiento de detección y clasificación de imágenes sin artefactos.	79-80
Tabla 16. Valores de media aritmética y desviación estándar de la clasificación del sistema de cada uno de los grupos muestrales..	85
Tabla 17. Tabla prueba T para cada grupo de estudio.	85
Tabla 18. Tabla prueba ANOVA para cada grupo de estudio.	86

Capítulo I

Aspectos generales

1.1 Problema u Oportunidad.

El diagnóstico del cáncer de mama ha impulsado a la constante investigación e implementación de nuevas técnicas y estrategias que conlleven al mejoramiento en la toma y lectura de imágenes mamográficas que se centralizan en mejorar la lectura y facilidad de diagnóstico. El Instituto Nacional del Cáncer (National Cancer Institute) de los Estados Unidos, en conjunto con expertos en mamografía, direccionaron sus investigaciones en la digitalización de las imágenes diagnósticas, bajo procesos de digitalización directas e indirectas, lo que llevó a la implementación de nuevas tecnologías para la obtención de las mismas, contando con las diferentes etapas que involucran tanto el proceso físico de irradiación y lectura de una placa CR para la digitalización correspondiente a una imagen adecuada. (Patiño, P., Hernández Restrepo, M. and Ortega Santamaría, J.; 2013).

El desarrollo de la tecnología en mamografía digital va unido con el perfeccionamiento constante de factores, como la tecnología de los monitores, la transmisión y el software de procesamiento de las imágenes, disminuyendo así, la presencia de artefactos. En este sentido, los artefactos consisten en una distorsión, presencia de adición o error en una imagen, donde no tiene relación con la región estudiada. Sin embargo, estos siguen presentes y es necesario conocer cada uno de ellos, analizando el tipo de artefacto bajo la clasificación de origen que tienen estos, con el objetivo de dar recomendaciones de tipo de ajuste o correctivo a vista ingenieril, además, para poder hacer una adecuada lectura de los estudios.(García K. J. y otros; 2021)

Si no se llevan a cabo correctamente los protocolos de examen, parámetros de uso, mantenimientos preventivos a los equipos emisores de Rayos X, en este caso la unidad mamográfica, pueden surgir artefactos dentro de los exámenes clínicos generados. Por ello, es necesario mantener la secuencia del protocolo de obtención de imagen, el cual debe funcionar correctamente dentro de los límites de rendimiento adecuados, de lo contrario,

puede dar lugar a una tasa de detección inferior de microcalcificaciones y lesiones de bajo contraste.

Según la *European Guidelines for Quality Assurance in Breast Cancer Screening and Diagnosis*, para asegurar el control de calidad adecuada, el radiólogo debe ser capaz de evaluar el estado del sistema de adquisición, incluyendo el detector, el sistema de procesamiento y el sistema de visualización, no obstante, una de las problemáticas en la actualidad, es que muchos de los profesionales de la salud no cuentan con capacitaciones en esta área. Por lo tanto, la oportunidad del diseño de un sistema de detección de artefactos en imágenes mamográficas, además de detectar artefactos, tiene la posibilidad de considerar revisiones en ciertos componentes del equipo de unidad mamográfica, salvaguardando así la seguridad del paciente, evitando patologías no seguras, y exposiciones repetitivas de Rayos X. (Patiño, P., Hernández Restrepo, M. and Ortega Santamaría, J.; 2013).

1.2 Descripción del problema

Los procedimientos realizados para el diagnósticos mediante el uso de equipos emisores de Rayos X, son muy usados en la actualidad por los profesionales de la salud expertos en radiología, con el fin de generar imágenes de tejidos y estructuras anatómicas internas del paciente bajo el principio de transferencia de los Rayos X que viajan a través del cuerpo y posteriormente pasan a través del detector de radiación al otro lado del paciente, formando así una imagen que muestra las diferentes densidades radiológicas de los tejidos representando las figuras anatómicas en escala de grises. (Centros para el control y prevención de enfermedades CDC, División de Prevención y Control del Cáncer, 2020). Entre estas técnicas se encuentran las mamografías, que corresponden a procedimientos radiográficos que se basan en el principio de los exámenes de Rayos X, y es implementado para la visualización del interior de las mamas, con el objetivo de identificar anomalías como calcificaciones o masas no deseadas. Cada una de las etapas para la obtención de la imagen final (mamografía) deben realizarse de la manera correcta, de lo contrario se pueden generar errores no deseados como artefactos y disminución de la calidad de estas. (RadiologyInfo.org , 2021)

Se ha demostrado que de los diversos equipos de imagen de diagnóstico empleados principalmente en las instituciones de imagenología pueden surgir diferentes tipos de artefactos, en este caso, imágenes mamográficas. (Patiño, P. Hernández Restrepo, M. and Ortega Santamaría, J., 2013). Los artefactos pueden surgir por la mala adecuación del paciente, tecnología, unidad mamográfica, software, entre otros, y estos se pueden presentar como disminución en la calidad de las imágenes representadas en distorsión, adición y/o errores, afectando la correcta lectura de los resultados generando dificultad en la interpretación, además de la realización de exámenes adicionales innecesarios tales como ultrasonidos y biopsias. Uno de los aspectos más importantes es la seguridad del paciente, es por ello que una mala interpretación de un examen de mamografía por su baja calidad puede perjudicar al paciente, además, generar desconfianza y preocupaciones innecesarias a los usuarios (García KJ. y otros, 2021). Dentro de las consecuencias de una mala lectura e interpretación de mamografía está la detección de cuerpos extraños y microcalcificaciones, siendo estas en realidad un artefacto. También puede ocurrir lo contrario, donde realmente exista un cuerpo extraño, pero la unidad mamográfica no esté tomando correctamente la imagen. Estos problemas pueden surgir y generalmente retrasan los tratamientos ya que existe la posibilidad que se deban realizar nuevamente.

Teniendo en cuenta lo anterior, la identificación de los artefactos en imágenes mamográficas se ha convertido en un reto por la poca familiaridad y conocimientos de ellos por parte de los especialistas, incurriendo en diagnósticos posiblemente erróneos. (Patiño, P., Hernández Restrepo, M. and Ortega Santamaría, J.; 2013). Por ello, la existencia de un software que identifique los diferentes tipos de artefactos en una imagen mamográfica o, al contrario, descarte la misma presencia de artefactos, se hace necesario en los diferentes centros de imagenología, para brindar una mayor confiabilidad en los resultados y contribuir al mejoramiento de los procesos de captura de las imágenes.

1.3 Justificación

En el mundo, el cáncer de mama es el tipo de cáncer más común entre la población femenina, teniendo en el 2020 una incidencia del 47.6 casos por cada 100.000 personas, constituyéndose como una de las principales causas de muerte en mujeres a nivel mundial con un porcentaje de mortalidad del 13.6 casos por cada 100.000 personas (Globocan GC., 2020). En Colombia la tendencia se mantiene. Para el año 2018, la tasa de incidencia fue de 63.9 casos por cada 100.000 mujeres, y según lo reportado por el Departamento Administrativo Nacional de Estadística (DANE) en el 2020 fallecieron 4.411 personas a causa de un tumor maligno en la mama.

Teniendo en cuenta que en la actualidad la mamografía se caracteriza por ser uno de los exámenes médicos más utilizados en la valoración del cáncer de mama (Guertin, M y otros, 2018), debido a su alta eficiencia en la detección de esta enfermedad en fases preclínicas (Hellquist; 2010) se hace necesario el control de calidad de las imágenes mamográficas. Para realizar un correcto dictamen clínico, las imágenes deben contar con una alta resolución, así como con un buen contraste, siendo esta una de las principales dificultades a las que se enfrentan los profesionales de la salud a la hora de realizar el diagnóstico de esta enfermedad. La baja calidad de las mamografías es un fenómeno común en los centros que realizan este tipo de estudios, como se observó en una investigación realizada por la Universidad de Caldas, en donde se demostró que el 75 % de estos exámenes presentan algún tipo de artefacto que dificultan el diagnóstico y tratamiento de los pacientes (García KJ y otros, 2021).

Por lo anterior, se hace imprescindible emplear un sistema encaminado a ubicar y clasificar artefactos relacionados a la captura de las mamografías, particularmente aquellos debidos a errores de procesamiento del software o deficiencias en el detector. Tener en cuenta las causas, es un factor esencial para que las instituciones puedan tomar medidas preventivas y correctivas, garantizando la calidad de la imagen y la lectura de la misma, con el fin de brindar un diagnóstico preciso que permita un tratamiento oportuno.

1.4 Pregunta problema

¿Cómo detectar artefactos mediante técnicas de procesamiento en imágenes e inteligencia artificial en pro de la mejora en la calidad de las imágenes de mamografías en una unidad de imagenología?

1.5 Objetivo general

Desarrollar una interfaz de usuario para la detección de artefactos de captura en imágenes de mamografías mediante la implementación de técnicas de procesamiento de imágenes e inteligencia artificial.

1.6 Objetivos específicos

1. Comparar las técnicas de procesamiento de imágenes e inteligencia artificial empleadas en la detección de artefactos de captura en mamografías mediante un método de diseño en ingeniería para la selección de la mejor técnica.
2. Elaborar una interfaz de usuario para la detección de artefactos asociados a las capturas mamográficas a través de la implementación del software de programación libre.
3. Evaluar la interfaz de detección de artefactos de captura en imágenes mamográficas para establecer la precisión del aplicativo mediante pruebas de funcionalidad.

1.7 Limitaciones y Delimitaciones

El desarrollo del presente estudio está limitado en primera instancia debido a la escasez de información existente con relación a la detección y clasificación de artefactos en imágenes mamográficas, ya que, si bien hay distintas investigaciones en las que se implementan diversas técnicas tanto de inteligencia artificial, como de procesamiento de imágenes, en cuanto a la identificación de estructuras, la bibliografía en donde se plantee una metodología para definir el tipo de artefacto presente en una mamografía es escasa.

En relación a lo anteriormente mencionado, este proyecto se encuentra así mismo delimitado a la dificultad de acceder a un banco de imágenes de mamografías que cuente con la suficiente cantidad de datos, y que a su vez, estos contengan artefactos que surjan como consecuencia del mal funcionamiento del equipo. Así mismo, existe la posibilidad de obtener las imágenes directamente de una institución médica que preste el servicio de mamografía. Sin embargo, esta opción cuenta con la dificultad de que se deben tener en cuenta ciertos procesos legales encaminados específicamente a todo lo relacionado con investigaciones en humanos, como lo es, realizar el convenio entre las instituciones para que la información se de uso netamente académico, aprobación por parte del comité de ética y la implementación de consentimientos informados.

Capítulo II

Marco Teórico y Estado del Arte

2.1 Marco teórico

2.1.1 Artefacto

Un artefacto o artificio se define como una distorsión, adición o error en una imagen que no tiene correlato en el sujeto o región anatómica estudiada. Como término, deriva de las palabras latinas *artis* (artificial) y *actum* (efecto), y refiere a un efecto artificial que altera la calidad y fidelidad de una imagen, pudiendo encubrir una patología o crear hallazgos falsos (Sartori y otros, 2015). Estas irregularidades normalmente están relacionadas a los valores de píxel de un área más o menos extensa en una imagen radiográfica, no vinculado con las propiedades del objeto. Pueden ser producidas por componentes del equipo, mala praxis, factores relacionados al paciente, mal procesamiento del software, etc.

2.1.2 Mamografía.

La mamografía o mamograma de exploración es un tipo específico de toma de imágenes de los senos que utiliza Rayos X de baja dosis para detectar en forma temprana enfermedades, principalmente microcalcificaciones y cáncer, antes de que la mujer presente síntomas (Radiological Society of North America, Inc. (RSNA)., 2021). El procedimiento llevado a cabo en el examen es el siguiente: la paciente se colocará de pie frente a una máquina especial de Rayos X acompañada de una tecnóloga, colocará su mama sobre una placa de plástico. Después cubrirá la mama con otra placa, presionando firmemente, luego se aplanará la mama manteniéndola inmóvil para la toma de la radiografía. Los pasos se repiten para tomar una imagen del costado de la mama (Fig 1). Posteriormente, le sacarán una radiografía a la otra mama de la misma forma. Después de asegurarse que el procedimiento haya sido el correcto, los resultados son entregados al especialista para su interpretación (Centros para el control y prevención de enfermedades CDC, División de Prevención y Control del Cáncer, 2020).

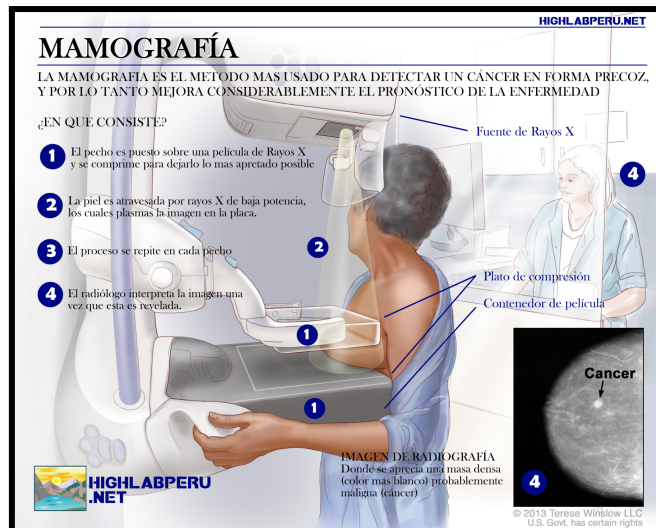


Fig 1. Mamografía: El mejor método para la detección precoz del cáncer de mama. Fuente. (Maria de los A. Hernandez, 2021)

2.1.3 Procesamiento de imágenes

El procesamiento digital de imágenes es el área de la ingeniería que se encarga de la extracción de mediciones, datos o información contenida en una imagen además de aquellas técnicas cuyo principal objetivo es facilitar la búsqueda e interpretación de la información contenida en ellas, como la alteración de la información visual para obtener mejores resultados o aislar algunas características particulares de la imagen. Un sistema de análisis de imágenes, se distingue debido a que tiene como parámetro de entrada una imagen, y cuyo resultado es comúnmente una salida numérica, en lugar de otra imagen esta salida es la información referente al contenido de la imagen de entrada. Sin embargo, para llegar desde la imagen original al conjunto de parámetros e información extraída de la misma, es necesario pasar por distintas etapas de procesamiento y filtrado donde se analiza la imagen y se adecúa para cierta aplicación específica; lo que implica que el resultado del procesamiento depende fuertemente del problema que se esté abordando, en este caso, una necesidad clínica, que consiste en la extracción de artefactos en imágenes de mamografía (Aguirre, D; 2012) (Pérez, P., & Valente., M., 2018).

2.1.4 Mamógrafo.

Las unidades de mamografía o mamógrafos, son equipos de Rayos X utilizados especialmente para obtener imágenes de la mama (Ver figura 2). Hay dos tipos de mamógrafos, los mamógrafos análogos y los mamógrafos digitales (Barr y otros, 2016), tanto la mamografía convencional (analógica) como la mamografía digital usan Rayos X para la obtención de imágenes. En la mamografía convencional la imagen se obtiene usando detectores pantalla-película, que graban los fotones de radiación que pasan a través de la mama. En la mamografía digital, la imagen es procesada y guardada por programas computarizados e impresos posteriormente, cuantas veces sean necesarias (Santo da Anunciação, P., 2017).



Fig 2. Mamógrafo MX-600. Fuente. (Santo da Anunciação, P., 2017).

2.1.5 Imagen digital.

Una imagen digital es una figura formada por píxeles (*Picture elements*) que se disponen en una trama denominada mapa de bits. Cada pixel es la combinación de valores de color y brillo en una posición determinada de tipo numerico, en donde los índices de fila y de columna identifican un punto de la imagen y el valor que este representa en la matriz indica el nivel de gris en ese píxel (Campos y Bozal, 2006).

2.1.6 Segmentación.

La segmentación es una técnica utilizada en el procesamiento de imágenes, que consiste en subdividir una imagen en sus partes constituyentes u objetos, con el fin de separar las partes de interés del resto de la imagen. Otra definición considera a la segmentación como la clasificación de los puntos de la imagen (píxeles), indicando las clases a la que pertenecen los diferentes píxeles (Palomino y concha, 2014).

Dentro de la etapa de segmentación que hace parte del procesamiento digital de imágenes se encuentran una gran variedad de técnicas, las cuales podemos agrupar dentro de estos tres grupos, detección de bordes, umbralización y basado en regiones.

- Detección de bordes: La imagen está compuesta por objetos de diversas características y en la detección de bordes se localiza la intersección de estos objetos para poder determinar sus regiones e información.
- Umbralización: El umbral se precisa como una función que convierte una imagen con diferentes tonalidades en una imagen en blanco y negro. Se elige un umbral que permita agrupar los píxeles que hacen parte de los objetos de la imagen, diferenciándolos del fondo. El histograma de una imagen es una función discreta que se plantea como el número de píxeles gris sobre el número de píxeles de la imagen. Por lo tanto, la segmentación por histograma consiste en elegir uno o varios umbrales para poder reunir los puntos de la imagen con respecto a sus características y de acuerdo a sus niveles de gris.
- Basado en regiones: El objetivo principal de esta técnica de segmentación es dirigirse en la búsqueda de las regiones de interés de la imagen. La imagen se divide en regiones cada una con características particulares que la diferencia de las otras regiones; esto se da porque los píxeles de una región poseen características similares (Gómez y Guerrero, 2016).

2.2 Estado del Arte

En el año 2012, Chevalier. M y otros, de la Universidad Complutense de Madrid, la Universidad Diego Portales y el Centro de Desarrollo de Tecnología Nuclear, llevaron a cabo una investigación que tenía como objetivo describir los parámetros y procedimientos relevantes para el control de calidad de los sistemas de mamografía digital, tanto para la radiografía computarizada (RC), como para los detectores de panel plano (RD). En el documento, como se expuso anteriormente, suministra información de tipo general referente a los diferentes tipos de funcionamiento de los mamógrafos dependiendo de si es de RC, o de RD, bien sea de forma indirecta o directa, mostrando el espectro de Rayos X necesario para el correcto funcionamiento de ambos sistemas para garantizar la calidad del proceso, la dosificación y el control automático de exposición de la misma, y como, también éste factor afecta la calidad de la mamografía, junto con el sistema de compresión y los posibles artefactos y sus métodos matemáticos de detección, como lo son la desviación estándar del número de fotones absorbidos, o un mapa de ganancia para corregir la no uniformidad de la sensibilidad de los detectores. Además, sirve como referencia teórica al relacionar los conceptos de artefacto y dosimetría en mamografía. Este documento en particular aporta al proyecto la información referente a los parámetros necesarios para garantizar la calidad de las imágenes mamográficas, algunos tipos de artefactos que pueden presentarse en la imagen, así como sus métodos matemáticos de detección. (Chevalier, M y otros, 2012)

Ribli, Horváth y Unger en el año 2018, realizaron un estudio en donde se planteó un sistema de detección asistida por computador (DAC) basado en redes neuronales convolucionales o Faster R-CNN, con el propósito de detectar y clasificar lesiones en una mamografía sin ningún tipo de intervención humana. Con la finalidad de entrenar el modelo se tomaron del *Digital Database for Screening Mammography* (DDSM) un conjunto de 2,620 imágenes digitalizadas con algún tipo de lesión, las cuales son en primera instancia analizadas por una rama de capas convolucionales llamada Red de propuesta de región (RPR) encargada de detectar y localizar objetos en la imagen (Ver figura 3), utilizando cajas de detección con diferentes tamaños y relaciones de aspecto para encontrar objetos con diferentes tamaños y formas, posteriormente otra rama de la red neuronal evalúa la información procedente de cada región para que a partir de esta se lleve a cabo la tarea de

clasificación, identificando 2 tipos de objetos, lesiones benigna o malignas.(Ribli, D., Horváth, A., Unger, Z, 2018). Este artículo resalta respecto al proyecto en la metodología utilizada en el desarrollo de un sistema de detección de las estructuras deseadas, en este caso en específico que se busca identificar artefactos presentes en imágenes mamográficas.

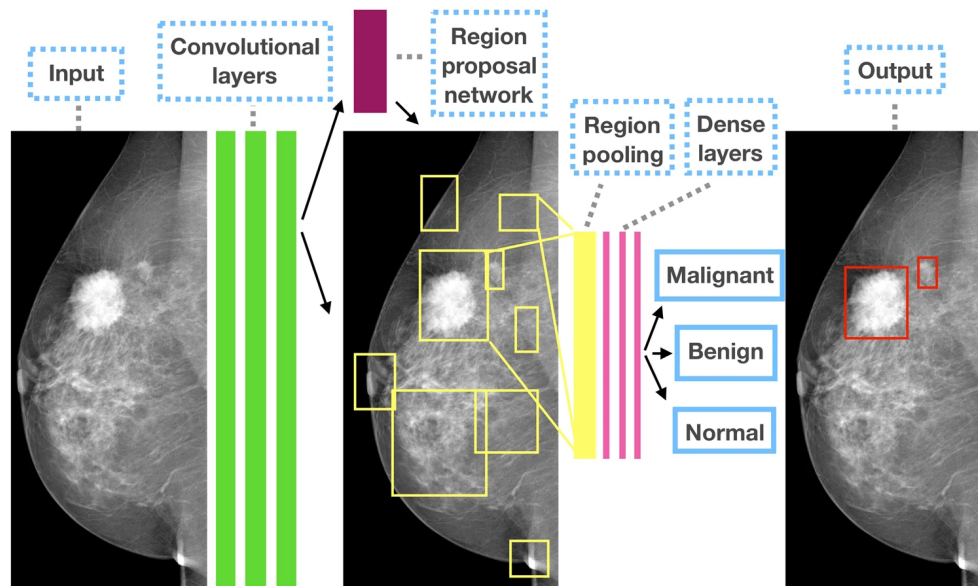


Fig 3. Modelo de clasificación basado en R-CNN. Fuente.(Ribli, D., Horváth, A., Unger, Z; 2018).

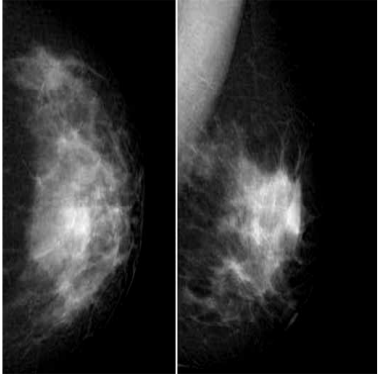
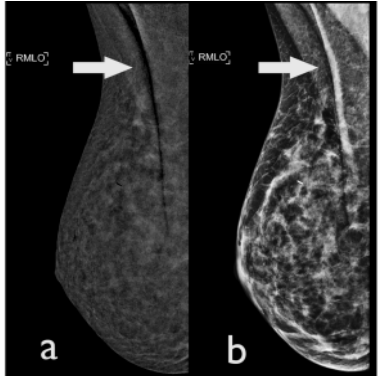
En el estudio denominado “*Automatic detection of anomalies in screening mammograms*” (Kendall y otros;2013) se propone una técnica de clasificación basado en un *Wavelet Filter Classifier* (WFC) para identificar anomalías en imágenes mamográficas. Para realizar este método, se formó una base de datos recolectando imágenes tanto del *Digital Database for Screening Mammography* (DDSM), como del *Mammographic Images Analysis Society’s database* (MIAS), imágenes que mediante el uso de transformaciones 2D discretas, son procesadas, generando un conjunto de mapas de diferentes tamaños. Una vez se lleva a cabo este proceso, se procede a calcular las características estadísticas de cada mapa y determinar la probabilidad de que la imagen tenga alguna anomalía. Su aporte al proyecto se ve reflejado en información sobre la delimitación de regiones de interés para realizar la extracción de características, con el fin de clasificar artefactos en las imágenes

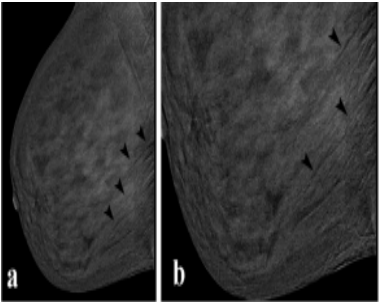
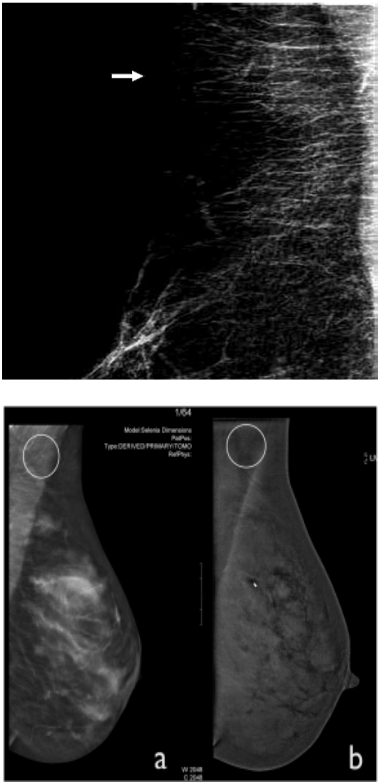
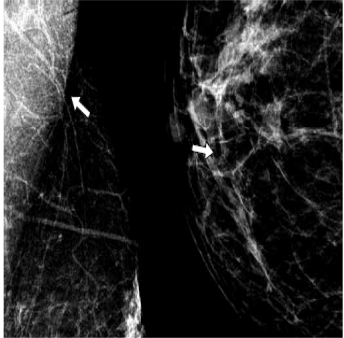
Los investigadores Patiño, Restrepo y Santamaria, en el estudio “Artefactos en mamografía digital”, plasman las bases teóricas relacionadas a la mamografía, en donde presentan en primera instancia el concepto de mamografía analógica y digital, para posteriormente ahondar en los distintos tipos de artificios que usualmente se generan en las

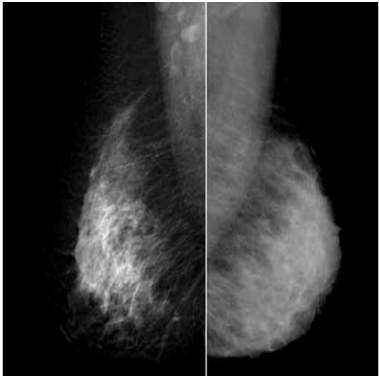
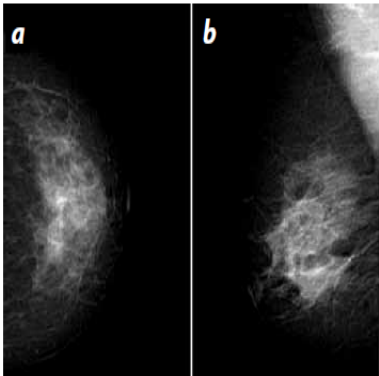

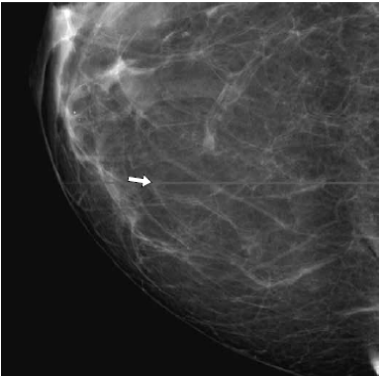
imágenes de mamografía y que pueden afectar el diagnóstico realizado por los profesionales de la salud, dando como resultado lecturas erróneas. Suministrando al proyecto la información necesaria para clasificar los artefactos que se pueden presentar las imágenes mamográficas en 5 categorías que se detallan en la tabla 1. Adicionalmente, se hace la especificación de las causas de estas irregularidades en la imagen y como se observa en la imagen, datos que serán necesarios a la hora de que el software haga la detección de las mismas. Con base a esta información, se realizó una tabla (Tabla 1) en donde se adjunta la clasificación de estos artefactos, su causa y apariencia (Patiño y otros, 2013).

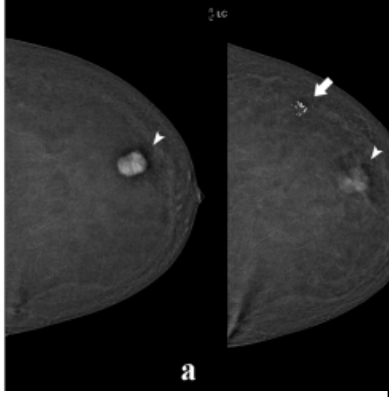
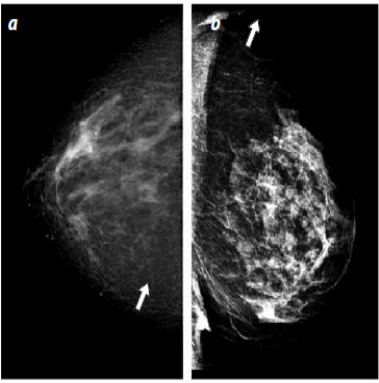
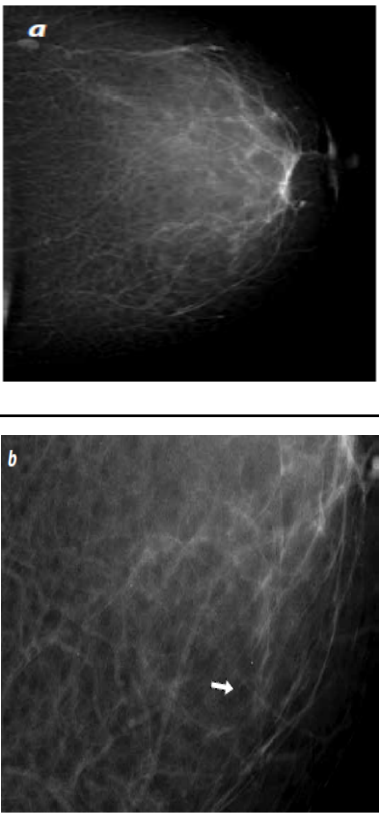
Dentro de la clasificación de los artefactos, existen 5 categorías, las cuales son:

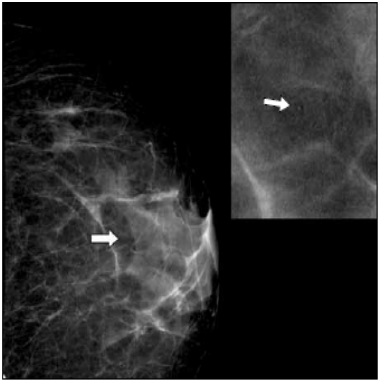
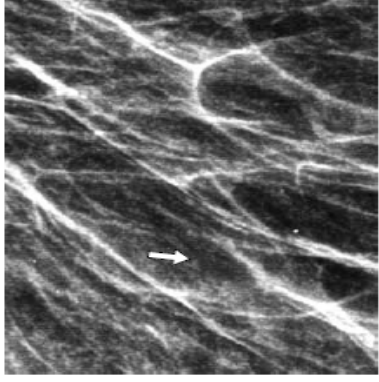
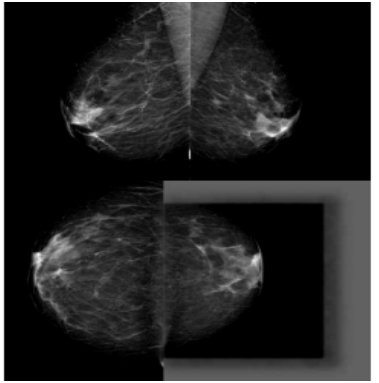
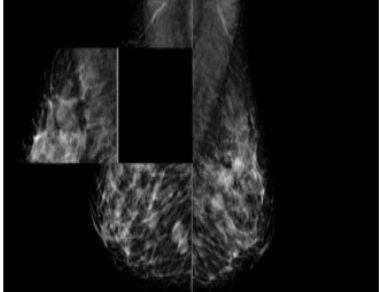
Tabla 1. Descripción, causa, apariencia y visualización de cada uno de las clasificación es de artefactos que se pueden presentar en imágenes mamográficas. Fuente. Autoría propia.

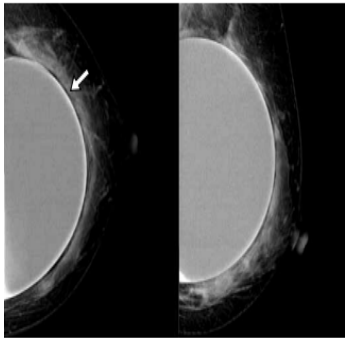
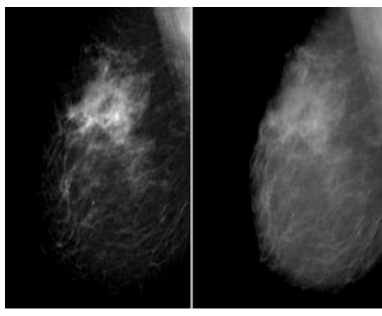
Categoría	Tipo de artefacto	Causa	Apariencia del artefacto	Imagen
Asociados al paciente	Artefacto de movimiento	Largo tiempo de exposición	Imagen con apariencia borrosa en la cual no se diferencian adecuadamente las estructuras.	
	Artefacto de aire atrapado	Este artefacto es causado por el contacto parcial entre la piel y el detector o la placa de compresión	Se crea una presencia de aire que se manifiesta como un artefacto oscuro en el área de contacto parcial.	

	Artefacto <i>ripple</i>	Se atribuye bien sea a el movimiento del paciente o a las pulsaciones cardiacas	Se visualizan comúnmente como una alternancia de imágenes blancas y negras	
	Artefacto antitranspirante por	Presencia antitranspirante de	En imágenes LE, aparece como pequeños puntos de color blanco, mientras que en imágenes re combinadas se ven como puntos negros	
Asociados a la tecnología	Artefacto por polvo	Presencia de polvo en el equipo	Se presencias puntos blancos, generalmente más blancos que las calcificaciones	

	Artefacto de ruido	Parámetros no apropiados o la exposición no es suficientemente larga	Imágenes totalmente borrosas	
Subexposición	Artefacto de sal y pimienta	Exposición prematuramente abortada o a una fotocélula puesta accidentalmente cerca del borde de la mama	Se observan áreas moteadas oscuras dispersas y no permite diferenciar la imagen anatómica del ruido.	
	Artefacto de líneas de la grilla	Inadecuado ajuste de la exposición, kilovoltaje alto y más bajo, con tiempos de exposición bajos en comparación con el tiempo de movimientos de la grilla	Se observan líneas presentan una disposición oblicua con un ángulo de 45°	
Unidad de mamografía	Artefacto por polvo en la lectura láser de la placa	Polvo en la lectura láser de la placa	Se observan líneas blancas y/o negras, que siguen la dirección de lectura y son perpendiculares a la mamografía.	

	<p>Artefacto <i>contrast splatter</i></p>	<p>Se presenta cuando el tubo se desprende del inyector de poder y el medio de contraste salpica en el equipo o la piel</p>	<p>Se reconoce como puntos blancos similares a las microcalcificaciones</p>	
	<p>Artefacto por alineación incorrecta del colimador con el detector</p>	<p>Alineación incorrecta del colimador con el detector</p>	<p>Variación en la calidad de la lectura y generar pérdida del tejido mamario</p>	
	<p>Artefacto por píxeles defectuosos</p>	<p>Deterioro del detector</p>	<p>Defecto de un solo píxel</p>	

		Una descarga temprana de un detector único que aparece como una mancha blanca en la imagen	La descarga de ese detector aumenta la carga de los vecinos, lo que da como resultado un halo negro alrededor de la mancha blanca	
	Artefacto fantasma	Causado por un incorrecto aclaramiento electrónico del detector y es un problema en los sistemas que utilizan un detector amorfo de selenio.	Doble contorno visualizado en el contorno inferior.	
Asociados al Software	Artefacto de adquisición	El sistema lee mal el tamaño del detector	Pérdida de la calidad de la imagen y lleva a mediciones de distancia equivocadas	
			Imágenes con inclinación horizontal y desplazamiento de partes de la imagen	
	Artefacto de halo	Los algoritmos utilizados en el manejo de los datos pueden ser muy sensibles a los altos contrastes producidos por materiales extraños o por estructuras	Este artefacto es caracterizado por áreas curvilíneas de alta densidad por todo el borde	

		de alto contraste, como grandes calcificaciones.		
	Artefacto <i>Skin-line</i>	Se presenta en pacientes con mamas grandes o con prótesis.	El borde de la mama se pierde debido a un procesamiento inadecuado del algoritmo	

La categoría de artefactos seleccionada para el desarrollo del proyecto, son los artefactos relacionados a la unidad mamográfica y al software del equipo, ya que con la identificación de estos se pueden predecir sus causales y generar una alerta a las instituciones de imagenología para que puedan tomar medidas preventivas y correctivas necesarias en la unidad o software, de tal manera que se garantice la calidad de la imagen y la lectura de la misma, a diferencia de los diferentes artefactos relacionados a los pacientes ya que estos se pueden evitar a través de capacitaciones al personal encargado y a los pacientes, para un correcto protocolo de preparación y posicionamiento a la hora de realizar la mamografía.

2.3 Trayecto Histórico

En Colombia el cáncer de mama en la población femenina ocupa la más alta tasa en incidencia y la segunda en mortalidad entre todos los tipos de cáncer, con una tendencia al incremento, por lo que el Ministerio de la Salud y Protección Social, a través del Instituto Nacional de Cancerología (INC), han considerado fortalecer los programas de detección temprana con mamografía y examen clínico entre las mujeres mayores de 50 años (Harley Alejo Martínez y otros, 2013). Por ello, se han implementado investigaciones, proyectos y métodos para controlar la calidad de los servicios prestados en los centros de mamografía del país, donde se establecen protocolos que permiten la evaluación de los procesos de la

obtención de la mamografía hasta la calidad de la imagen, y evaluar si están dentro de los márgenes de tolerancia o no (Harley Alejo Martínez y otros, 2013). Harley Alejo-Martínez junto a su equipo realizaron una investigación durante los años 2010 y 2012, donde se realizaron visitas de control de calidad a treinta y nueve (39) centros de mamografía en seis ciudades de Colombia donde se contempló realizar pruebas de control de calidad basadas en el protocolo “Control de calidad para los servicios de mamografía analógica” propuesto por el Instituto Nacional de Cancerología (E.S.E.), dieciséis (16) las pruebas de control de calidad, así como los criterios de calificación. Donde se encontraron anomalías desde los protocolos para los pacientes hasta problemas en la unidad mamográfica como vibraciones e indicador de la fuerza de compresión (Harley Alejo Martínez y otros, 2013).

También se llevó a cabo una investigación de evaluación de calidad, lectura y servicio de mamografía en 4 centros de imagenología de la ciudad de Manizales - Colombia, esta investigación fue realizada en 2019, la cual fue liderada por Karol Julieth García y su equipo investigativo. Dentro de los resultados que obtuvieron observaron baja calidad en las imágenes que se obtenían en los centros, ya que presentaban artificios en un 75 % de ellas, además de identificación y rotulaciones deficientes, entre otros. Como conclusión afirman que: *“Los centros de imágenes diagnósticas evaluados están habilitados para el funcionamiento, pero se encontraron deficiencias importantes en la calidad de las imágenes y en su lectura, lo que pone en manifiesto la necesidad de establecer estándares de calidad y mejorar los aspectos que se puedan mejorar”* (Karol Julieth García y otros, 2021).

En Colombia hay poca literatura existentes de sistemas de detección de artefactos en imágenes, por lo que se hace necesario un sistema que permita detectar la presencia de artefactos en las imágenes mamográficas, para mantener estándares de calidad y supervisar el estado de los equipos de imagenología que general artefactos afectando la calidad de la prestación del servicio a los pacientes.

2.4 Marco legal e implicaciones éticas.

- Resolución 8430 de 1993. Por la cual se establecen las normas científicas, técnicas y administrativas para la investigación en salud. Ministerio de salud y protección social.

Según lo establecido por la resolución 8430 de 1993, este proyecto se clasifica en la categoría de investigación sin riesgo, que son estudios que emplean técnicas y métodos de investigación documental retrospectivos y aquellos en los que no se realiza ninguna

intervención o modificación intencionada de las variables biológicas, fisiológicas, psicológicas o sociales de los individuos que participan en el estudio, entre los que se consideran: revisión de historias clínicas, entrevistas, cuestionarios y otros en los que no se le identifique ni se traten aspectos sensitivos de su conducta (Min. salud y protección social, 1993). Esto se concluye teniendo en cuenta que para el desarrollo de este proyecto se hará uso de un banco de imágenes y no se tendrá un contacto directo con los pacientes de el servicio de mamografía, por lo que requisitos como el permiso de un comité de ética, consentimiento informado de la población objeto de estudio no son aplicables a este proyecto de investigación.

- Ley estatutaria 1581 de 2012, Por la cual se dictan disposiciones generales para la protección de datos personales.

La presente ley tiene por objeto desarrollar el derecho constitucional que tienen todas las personas a conocer, actualizar y rectificar las informaciones que se hayan recogido sobre ellas en bases de datos o archivos, y los demás derechos, libertades y garantías constitucionales a que se refiere el artículo 15 de la Constitución Política; así como el derecho a la información consagrado en el artículo 20 de la misma. Este proyecto comprende los principios rectores establecidos en el TÍTULO II de la ley, además de la categorización de la base de datos como sensible, como la aplicación de los derechos, condiciones de legalidad, procedimientos y deberes para el tratamiento de los datos.

- Ley 23 de 1982, Por la cual se establecen las disposiciones de propiedad intelectual.

Según lo expuesto en los ART 1 y ART 2 del primer capítulo, en donde se estipula que todo tipo de obras literarias, artísticas, y/o científicas, como es el caso de esta investigación, contarán con la protección de los derechos de autor con el fin de limitar la reproducción, y lucramiento de terceras personas ajenas al estudio.

- Dirección Nacional de Derechos de Autor (DNDA).

La DNDA es una disciplina jurídica que ampara, protege y establece el derecho a la protección de bienes inmateriales de naturaleza intelectual, creativo, y de actividades conexas, donde encierra todas las creaciones literarias, artísticas, entre otros, provenientes del ingenio humano.

Capítulo III

Metodología

En el presente capítulo se pretende establecer la estructura de trabajo para desarrollar esta investigación como se ilustra en la figura 4, este proceso se divide en nueve secciones, en donde inicialmente se hace una consulta de las diferentes técnicas de procesamiento de imágenes e inteligencia artificial existentes para la detección de artefactos de capturas en mamografías, para posteriormente proceder a contrastar las técnicas evaluadas anteriormente y en tercera instancia poder seleccionar la técnica más adecuada para llevar a cabo este proyecto. Como cuarto paso se elabora un diagrama de flujo que represente la detección de artefactos en mamografías, con el fin de ser usado como base para el desarrollo tanto del algoritmo, como de la interfaz de usuario del sistema para la detección de artefactos relacionados a la captura en imágenes mamográficas. Finalmente en conjunto, los momentos siete, ocho y nueve representan las pruebas de funcionamiento efectuadas, así como el análisis estadístico de los resultados obtenidos de estas pruebas.

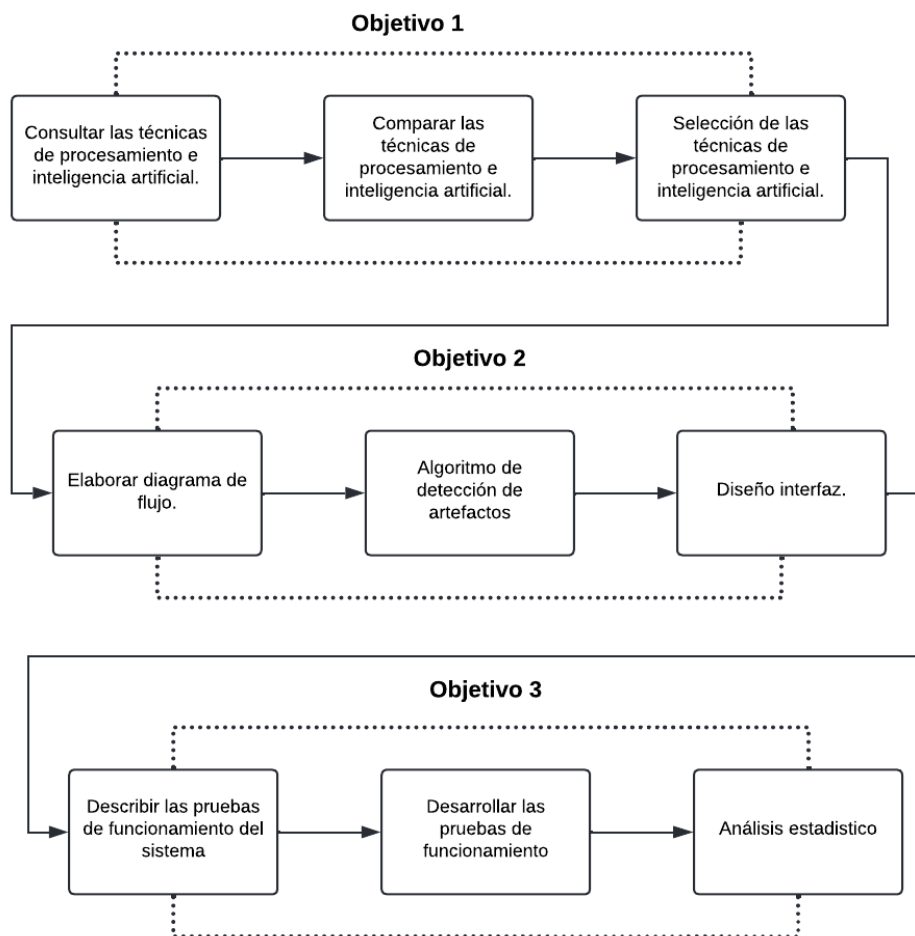


Fig 4. Diagrama de bloques de la metodología aplicada. Fuente. Autoría propia.

3.1 Consulta de las técnicas de procesamiento de imágenes e inteligencia artificial.

Para determinar la base de datos a través de la revisión bibliográfica enfocada al procesamiento de imágenes médicas e inteligencia artificial se identificarán y seleccionarán las diferentes técnicas usadas por los autores realizando una descripción de cada una de ellas, para esto se diseña un algoritmo de búsqueda con base a palabras clave como lo son “Inteligencia artificial”, “Mamografía”, “Artefacto”, “procesamiento de imágenes” y “Detección”, con lo cual se busca definir y delimitar la búsqueda. Así mismo, es necesario que estos términos sean tipo DeCS y MESH para implementarlos en función de los diferentes operadores AND / OR / NOT, según sea la necesidad.

Para las técnicas de inteligencia artificial se implementó la siguiente combinación de palabras claves:

- ((Artificial intelligence) AND (DYCOM)) AND (detection)
- ((Artifact[MeSH Terms]) AND (quality control[MeSH Terms])) AND (mammography[MeSH Terms])
- ((Artifact[MeSH Terms]) OR (quality control[MeSH Terms])) AND (mammography[MeSH Terms])
- ((Artifact[MeSH Terms]) AND (quality control[MeSH Terms])) AND (mammography[MeSH Terms]) NOT Software[MeSH Terms])

Para las técnicas de procesamiento de imágenes biomédicas se implementó el siguiente algoritmo de búsqueda:

- ((mammography[MeSH Terms])OR (image processing, computer assisted[MeSH Terms]) AND (Software[MeSH Terms]) AND (Artifact[MeSH Terms]))
- ((mammography[MeSH Terms])AND (image processing, computer assisted[MeSH Terms]) AND (Artifact[MeSH Terms]))
- ((mammography[MeSH Terms])NOT (image processing, computer assisted[MeSH Terms]) AND (Artifact[MeSH Terms]))

Se consideraron publicaciones a partir del año 2010 hasta la actualidad, y que estos presentaran *Free full text*. Se llevó a cabo un amplio estudio e identificación del tipo de técnicas ya mencionadas, para luego recolectar y analizar su posible uso para el proyecto.

3.2 Contrastar las técnicas de procesamiento de imágenes e inteligencia artificial.

Se desarrolla una tabla comparativa (Ver Tabla 2) que aborde cada una de las técnicas de procesamiento de imágenes médicas e inteligencia artificial para la detección de artefactos de capturas en mamografías, describiendo las características de alcance, definición, software de aplicación, principio matemático o de funcionamiento, posibles resultados, esquema descriptivo, aporte al proyecto y capacidad de aplicación para la identificación de los distintos tipos de artefactos en imágenes biomédicas.

Tabla 2. Modelo del formato de tabla resumen de los criterios y conceptos que se escogieron para la selección de las técnicas de procesamiento de imágenes. Fuente. Autoría propia.

Técnica	Definición	Funcionamiento	Esquemático
Técnica 1			
Técnica 2			
Técnica 3			
Técnica 4			
Técnica n...			

3.3 Selección de la técnica de procesamiento de imágenes e inteligencia artificial.

Para contrastar cada una de las técnicas de inteligencia artificial consultadas bajo características específicas, se realiza una tabla comparativa, esta tabla está definida por 5 conceptos y 5 criterios, para aplicarla al modelo de selección PUGH.

Después de definir las propiedades necesarias para realizar una caracterización de las técnicas de inteligencia artificial, se organiza la tabla resumen donde se pueda almacenar cada uno de los rasgos de forma organizada como lo muestra la siguiente tabla (Ver tabla 3).

Tabla 3. Modelo del formato de tabla resumen de los criterios y conceptos que se escogieron para la selección de las técnicas de Inteligencia Artificial. Fuente. Autoría propia.

Criterios	Conceptos					
	Referencia	Concepto 1	Concepto 2	Concepto 3	Concepto 4	Concepto 5
Criterio 1						
Criterio 2						
Criterio 3						
Criterio 4						
Criterio 5						

Total (-)					
Total (+)					
Total (Suma)					

Una vez se tengan claras las características de cada concepto a evaluar se lleva a la implementación del método PUGH para la selección de la técnica más adecuada para el proyecto. Para llevar a cabo este método de selección se debe realizar una tabla donde se pueda asignar la calificación de los conceptos en relación a los criterios, en donde se puede usar el modelo presentado anteriormente. Posteriormente, se debe tener un modelo o resultado deseado donde se cumpla una expectativa o característica ideal para llevar a cabo el proyecto. El valor de la calificación solo podrá ser negativo (-1), cuando el criterio que presenta el concepto está por debajo del esperado o necesitado para el proyecto; será neutro (0), cuando el criterio que presenta el concepto es igual que el esperado o necesitado para el proyecto y positivo (1), cuando el criterio que presenta el concepto está por encima del esperado o necesitado para el proyecto, es decir, mejor. Finalmente se realiza una suma de cuantos negativos, neutros y positivos obtuvo cada concepto, para visualizar sus pesos y posteriormente se realiza una suma general los resultados, es decir la suma de los -1, 0, y 1, para seleccionar el concepto o técnica que presente el mayor número positivo.

3.4 Diagrama de flujo.

Una vez seleccionadas las técnicas tanto de procesamiento de imágenes, como de inteligencia artificial más adecuadas según la etapa anterior, el siguiente paso a seguir es definir la arquitectura o estructura del sistema de detección de artefactos en mamografías, esto se

realiza mediante un diagrama de flujo, en donde se detallan paso a paso la red de funciones, componentes, las condiciones, procesos, entrada y salida de variable o información que se entregan durante todo el funcionamiento del sistema y que son necesarios conocer a la hora de desarrollar el algoritmo.

Para esto se organizará por fases cada proceso del funcionamiento del sistema:

- Selección de la imagen original y visualización de la misma.
- Establecer información de la imagen.
- Introducción de parámetros para la ejecución del algoritmo de detección (si se requiere).
- Realización de preprocesamiento de la imagen original (si se requiere).
- Aplicación del algoritmo de detección.
- Obtención de resultados.
- Visualización del artefacto de imagen teniendo como referencia la imagen original.
- Clasificación del artefacto, teniendo en cuenta la documentación.
- Exportación de datos y recomendaciones al personal de salud sobre el posible origen del artefacto.

3.5 Diseño algoritmo de detección y clasificación de artefactos.

El desarrollo inicial de la aplicación se centra en que los profesionales de la salud y expertos puedan diferenciar los artefactos presentes en la imágenes, bien sea de microcalcificaciones, tumores malignos y/o benignos. Por lo cual, teniendo como referencia el diagrama de flujo diseñado, se construye el algoritmo que represente cada una de las etapas descritas, para obtener el resultado esperado.

Para codificar el algoritmo se implementará el software libre Python, y se integra la respectivas librerías para leer y procesar imágenes en formato DICOM, para lograr identificar y clasificar los artefactos haciendo uso de la inteligencia artificial, permitiendo inicialmente seleccionar la imagen en escala de grises, que al usar la función histograma se puede observar la distribución de intensidades en la imagen representando un rango de valores de datos necesarios para llevar a cabo un proceso de umbralización, con el fin de determinar el valor

Threshold para hacer uso de la función binarización, en donde la mamografía será convertida de una escala de grises a una imagen a blanco y negro, creando una matriz de unos y ceros.

Una vez detectado el artefacto se usa una red neuronal convolucional entrenada con una base de datos con los artefactos ya catalogados para extraer las características de la imagen, para ello, la CNN contiene varias capas que identifican formas básicas y se van especializando hasta llegar a capas más profundas, haciendo posible efectuar la respectiva comparación entre la imagen procesada y la imagen de referencia y de esta manera lograr la clasificación.

3.6 Diseño de interfaz.

Al igual que con el algoritmo de detección y clasificación, se usa Python para la elaboración de la interfaz. Para lograr desarrollar una aplicación estética, didáctica y de fácil uso para el usuario se debe implementar librerías complementarias para diseñar la pantalla principal, la cual contará con un panel que contará con un botón para cargar la imagen deseada desde el explorador de archivos del ordenador, y un segundo botón para visualizar las imágenes mamográficas. Una vez se visualice la imagen se procede a hacer la identificación y clasificación del artefacto, para lo cual el usuario cuenta con un botón de inicio de programa y un botón de mostrar resultados, presentando una pestaña con los resultados, en donde se muestra la imagen original y la imagen con el artefacto detectado, así como un cuadro de texto en donde se especifique su respectiva catalogación.

Adicionalmente, se incluyen en el menú principal de la interfaz elementos de control como lo son las pestañas de minimizar, maximizar y cerrar la aplicación, un botón de eliminar información y/o archivos, un botón de finalizar el programa.

3.7 Descripción de las pruebas de funcionamiento.

El plan de pruebas se establece para la valoración de cada una de las etapas, y se debe contar con una base de datos de muestras de imágenes mamográficas, donde se encuentren identificados los diferentes artefactos relacionados a la unidad mamográfica y al software del equipo, con el fin de evaluar los procesos de:

-Selección y visualización de la imagen original

En esta evaluación se toman imágenes al azar de la base de datos de diferentes tamaños para la selección y visualización de los mismos. Se deben contar las imágenes visualizadas correctamente vs las no visualizadas correctamente.

-Identificación de artefactos

En esta evaluación se toman imágenes al azar de la base de datos de diferentes tipos de artefactos y someterlos al proceso de identificación de artefactos. Se deben contar las imágenes donde se detecta el artefacto correctamente vs donde no se detectó correctamente.

-Visualización de los resultados de la clasificación

En esta evaluación se toman imágenes al azar de la base de datos de diferentes tipos de artefactos y someterlos al proceso de identificación de artefactos y luego, visualizar los resultados de clasificación arrojados por el sistema. Se deben contar las imágenes donde los resultados de clasificación acertaron con el tipo de artefacto de la imagen mamográfica vs donde los resultados de clasificación no fueron correctos con respecto al tipo de artefacto de la imagen mamográfica.

3.8 Pruebas de software.

Por medio de las pruebas del software de aplicación, se verifica el adecuado funcionamiento del sistema, y se ejecuta haciendo uso de un banco de imágenes en formato DICOM. Para llevar a cabo estas pruebas de funcionamiento, inicialmente se debe seleccionar de la base de datos las imágenes que contengan artefactos derivados de la captura mamográfica.

Teniendo las imágenes necesarias se procede a realizar el siguiente protocolo con cada una de ellas:

1. Cargar y visualizar la imagen en el sistema de detección y clasificación de artefactos.
2. Dar inicio al sistema de detección de artefactos mamográficos.
3. Comparar los resultados obtenidos con las imágenes con artefactos previamente catalogados.
4. Analizar los resultados obtenidos y verificar que el sistema identificó el artefacto correctamente, o si por el contrario falló en la detección.

Este proceso se realiza con cada una de las imágenes con el fin de corroborar que se realice correctamente la identificación y clasificación de los artefactos relacionados a la captura de las imágenes mamográficas.

3.9 Análisis estadístico

El análisis estadístico de los resultados obtenidos en las pruebas de funcionamiento tiene como finalidad recopilar e interpretar la información para encontrar tendencias que indiquen el nivel de fiabilidad de los datos obtenidos. Para determinar la eficiencia del sistema de detección de artefactos asociados, el primer paso es determinar mediante el método matemático de Murray y Larry el tamaño de la muestra representativa, que indicará el número de veces que se debe analizar cada tipo de artefacto, es decir, cuántas imágenes se deben procesar por cada artefacto para establecer el grado de precisión del programa a la hora de clasificar.

La cantidad de pruebas determinadas según el modelo nombrado anteriormente para que puedan ser consideradas una muestra significativa, representativa y paramétrica, debe ser de 45 imágenes en formato DICOM de cada uno de los 3 artefactos y de 45 imágenes mamográficas en formato DICOM sin artefactos y/o patologías. El análisis inicia cuando se toman los datos de los resultados obtenidos de la detección y clasificación, con el fin de calcular su desviación estándar y media aritmética de cada conjunto de datos para realizar una prueba de distribución T y una prueba ANOVA.

Capítulo IV

Resultados obtenidos.

Una vez efectuada la metodología planteada, por medio de los resultados obtenidos se puede determinar y evaluar el cumplimiento de cada uno de los objetivos propuestos para el proyecto, los resultados serán expuestos según la secuencia en la que se realizaron, siendo el siguiente orden: i) Comparar las técnicas de procesamiento de imágenes e inteligencia artificial ii) Software de aplicación iii) Pruebas de funcionamiento del software de aplicación.

4.1 Consultar diferentes técnicas de procesamiento de imágenes e inteligencia artificial.

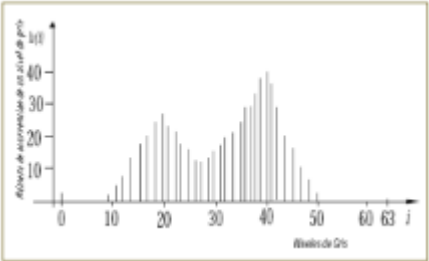
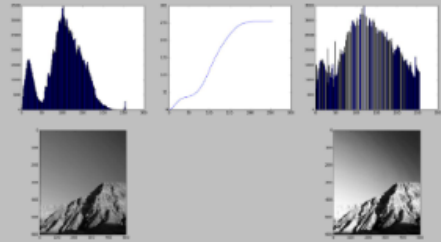
Se llevó a cabo la búsqueda de información relacionada a las distintas técnicas de procesamiento de imágenes e inteligencia artificial utilizadas para identificar y clasificar estructuras en imágenes mamográficas, utilizando como se expuso los algoritmos de búsqueda anteriormente mencionados, dando como resultado el siguiente listado de las posibles técnicas a implementar que son explicadas en la tabla 4 y tabla 5 respectivamente:

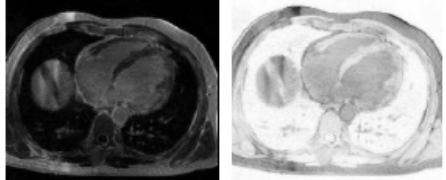
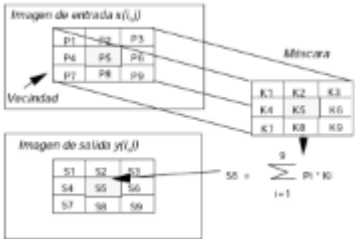
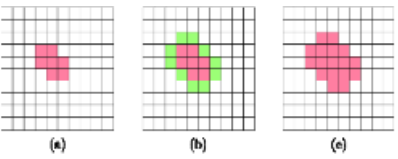
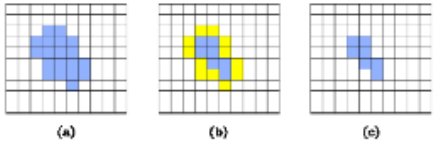
- Procesamiento de imágenes:
 - Filtrado basado en píxeles.
 - Ecuilización del histograma.
 - Negativo de una imagen.
 - Filtrado basado en regiones.
 - Filtro de dilatación.
 - Filtro de erosión.
 - Realizado de bordes.
 - Binarización.
 - Filtro pasa bajas.
 - Filtro Pasa altas.
 - Filtro mediana.
 - Transformada de fourier.
 - Filtro Gaussiano.
- Inteligencia artificial:
 - Red neuronal multicapa.
 - Red neuronal convolucional.
 - Sistemas difusos.
 - Inteligencia de enjambre.
 - Sistema inmune artificial.


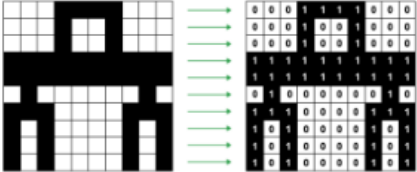
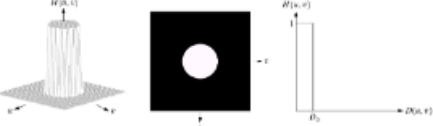
4.2 Comparación de las técnicas de procesamiento de imágenes e inteligencia artificial.

Una vez recopiladas todas las técnicas de procesamiento de imágenes e inteligencia artificial, se procede a realizar una tabla comparativa en la que se relacionen los resultados obtenidos en los factores de modo de funcionamiento, eficiencia y precisión de cada una de las técnicas, para la selección de la mejor herramienta de identificación de artefactos de capturas en mamografía. En esta etapa se elaboró una tabla para cada proceso, es decir una tabla (Ver tabla 4) para las técnicas de procesamiento implementadas con el fin de acondicionar la imagen, y una tabla (Ver tabla 5) para la clasificación de artefactos haciendo uso de la inteligencia artificial.

Tabla 4. Tabla comparativa de las técnicas de procesamiento de imágenes. Fuente. Autoría propia.

Técnicas de Procesamiento de imágenes			
Técnica	Definición	Funcionamiento	Esquemático
Filtrado basado en píxeles	Un histograma es una representación gráfica bidimensional que muestra la distribución de los valores de intensidad que tienen los píxeles de una imagen.	A través de la representación del histograma se modifica la intensidad de cada píxel en la imagen, y así poder intensificar la zona donde se encuentra el artefacto de imagen y disminuir la intensidad de los píxeles donde se encuentran la estructura anatómica. Es una técnica que modifica el valor que tiene un píxel sin modificar el valor de los píxeles vecinos, para ello utiliza la información del histograma de la imagen.	
Ecuilización del histograma	La ecuilización de histogramas es un método en el campo del procesamiento de imágenes que utiliza histogramas de imágenes para ajustar el contraste. Este método se usa generalmente para aumentar el contraste local de muchas imágenes, especialmente cuando el contraste de los datos útiles de la imagen es bastante cercano. De esta forma, el brillo se puede distribuir mejor en el histograma. Es una técnica	La ecuilización de histograma se refiere a aplanar el histograma de escala de grises de una imagen para que la probabilidad de distribución de cada valor de escala de grises en la imagen transformada sea la misma. La ecuilización de histograma es una función de transformación que puede lograr automáticamente este efecto solo ingresando la información del histograma de la imagen. Su idea básica es expandir el nivel de gris con una gran cantidad de píxeles en la imagen y comprimir el nivel de gris con una pequeña cantidad de píxeles	

	que distribuye la frecuencia de los niveles de gris de una imagen más uniformemente para que los cambios en la intensidad de la imagen sean más apreciables.	en la imagen, expandiendo así el rango dinámico del valor de la imagen original y mejorando el contraste y el tono de gris.	
Negativo de una imagen	Es una técnica que convierte porciones de una imagen que son claras en oscuras y las que son oscuras en claras. Se usa cuando se desea visualizar detalles en secciones brillantes de una imagen. Para lograr esto se resta a cada píxel el máximo valor posible de intensidad.	El negativo de una imagen se obtiene al implementar una transformación de negativo, dada por la fórmula: $T_n = L - 1 - r$. Esta técnica consiste en invertir los valores de intensidad de una imagen, produciendo el equivalente de un negativo fotográfico. Este tipo de procesamiento ayuda a mejorar los niveles de blanco o gris en una imagen.	
Filtrado basado en regiones	Es una técnica que permite realizar un barrido o recorrido a una imagen a partir de una matriz de píxeles diseñada, interactuando con cada píxel de la imagen realizando procesos de convolución para generar otra imagen resultante en función al filtro diseñado.	Se diseña e implementa una matriz de píxeles llamado vecindad el cual realizará extracción o modificación de cada píxel de la imagen, generando una imagen filtrada. La operación que lleva a cabo la máscara diseñada es de tipo convolucional.	
Filtro de dilatación	Este método consiste en aumentar el tamaño de objetos. La dilatación causa una extensión de una sección específica de una imagen, es una operación que ocasiona que todos los píxeles vecinos a un píxel perteneciente al objeto, se convierten en parte del objeto.	La técnica de dilatación de una imagen consiste en ocasionar un crecimiento de píxeles, es decir, se asigna un valor de 1 al fondo de la imagen que toque un píxel que forme parte de la región. Esto permite agrandar píxeles alrededor de la periferia de cada región y así aumentar su dimensión y rellenar agujeros dentro de la región.	
Filtro de erosión	Esta técnica permite la eliminación de los píxeles que se encuentran alrededor o bordeando un píxel, siempre y cuando haya al menos un píxel en medio o de fondo en el vecindario. Produciendo así una reducción de los objetos o eliminación de estos cuando son muy pequeños.	El método de erosión realiza una comprobación si el elemento estructurante Y está incluido en el conjunto X. Cuando esta condición no se cumple, el resultado de la erosión es el conjunto vacío. La erosión de un conjunto X por un elemento Y equivale al conjunto de puntos o elementos x, pertenecientes a X, de manera que cuando el elemento Y se traslada a ese punto, este queda incluido en X.	

<p>Realzado de bordes</p>	<p>La detección de bordes es un proceso que consiste en encontrar las secciones de una imagen que presentan diferencias importantes de tonos de gris; estas regiones son conocidas como bordes.</p>	<p>Los filtros basados en el gradiente de una imagen permiten caracterizar bordes, al implementar estos filtros en una imagen que esta en escala de grises, permite calcular el gradiente de la intensidad de brillo de cada pixel de la imagen, lo que proporciona una dirección del maximo incremento posible (de negro a blanco). Esta técnica representa que tan sutilmente cambia una imagen en cada pixel analizado, a su vez también muestra que tanto un punto determinado representa un borde en la imagen así como la orientación del mismo.</p>	 <p>Grises Altos Grises Medios Grises Medios</p>
<p>Binarización</p>	<p>La técnica de binarización consiste en la conversión de una imagen de escala de gris a blanco y negro (valores de 0 y 255), a partir de un valor umbral específico.</p>	<p>El principio de la binarización consiste en la ejecución de un recorrido por la imagen a procesar, con el fin de ejecutar la condición de conversión de la imagen de escala de gris a binaria a partir de un valor umbral de sensibilidad (valor T = Threshold) específico, tomando así los píxeles de la imagen valores de Negro (= 0) y blanco (= 255). Por ejemplo, los valores de pixel que sean mayores que el umbral determinado, su valor será cambiado a 255 (blanco) y los menores tendrán un valor de 0 (negro).</p>	
<p>Filtro pasa bajas</p>	<p>La técnica de filtro pasa bajas tiene la capacidad de atenuar las frecuencias altas y medias de una imagen, para generar como resultado una imagen que presente una cantidad disminuida de kontras, presentando así una apariencia más suave. Teniendo en cuenta lo anterior, esta técnica también es llamada como "suavizado de imágenes" o filtro de suavizado o de homogeneización.</p>	<p>La técnica del filtro pasa bajos o filtro promediador consiste en el reemplazo del valor de cada uno de los píxeles de una imagen usando el valor promedio de los píxeles vecinos, incluyéndose. Generando así el efecto de eliminación de los valores de píxeles que son poco representativos a comparación a sus vecinos.</p>	

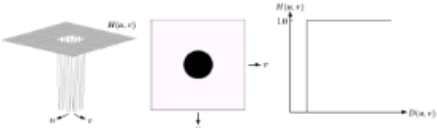
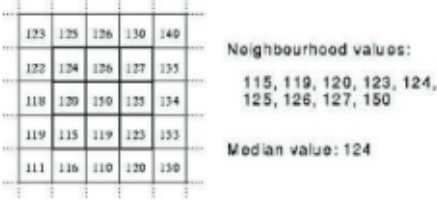
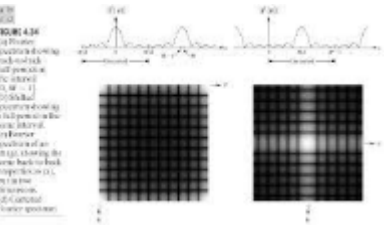
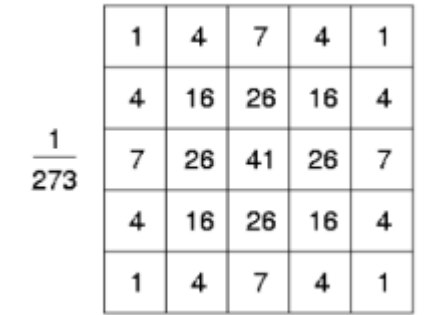
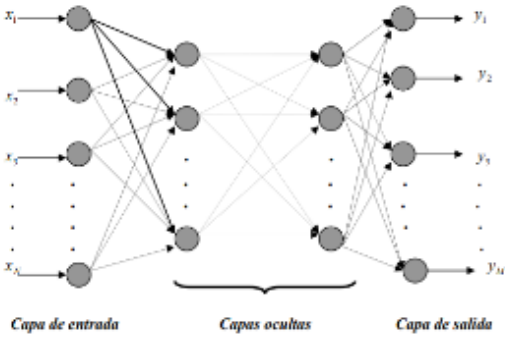
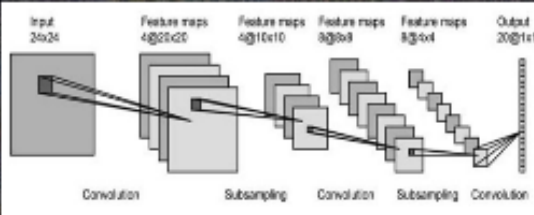


<p>Filtro Pasa altas</p>	<p>Los filtros de frecuencia alta o filtros pasa altas permiten resaltar frecuencias altas, para lograr esto el filtro, a la vez que suprime frecuencias bajas. Implementar este tipo de filtros ocasiona en las imágenes un realizado de límites, bordes agudos entre formas u objetos.</p>	<p>Un filtro paso-altas otorga un valor de cero a todas las frecuencias que estén por debajo de un valor asignado. Este filtro deja pasar todas las frecuencias que están fuera del círculo.</p>	
<p>Filtro mediana</p>	<p>El filtro mediano es una tecnología de procesamiento de señales no lineal basada en estadísticas. El ruido de la imagen digital o de la secuencia se reemplaza por el valor mediano del vecino (máscara). Los píxeles de la máscara se clasifican en el orden de sus niveles de gris y el valor medio del grupo se almacena para reemplazar el valor ruido.</p>	<p>Esta técnica consiste en la organización de forma ascendente o descendente de cada uno de los píxeles que están dentro de la matriz o ventana que se encuentra en análisis. Cuando se organizan cada uno de los píxeles, se selecciona el valor ubicado en el centro de la matriz de análisis, luego, se usa ese valor para colocarlo en el pixel que se encuentra posicionado en la imagen destino o que se está construyendo.</p>	
<p>Transformada de fourier</p>	<p>La transformada de Fourier se define como una transformación de la imagen de un dominio espacial a otro dominio llamado dominio de frecuencia o dominio de Fourier.</p>	<p>Es un herramienta de procesamiento utilizada para descomponer las imágenes en su seno y coseno. El resultado de esta transformación está representando en el dominio de la frecuencia, mientras que la imagen de entrada es el equivalente al dominio espacial. La representación de la transformada es $F(u,v)$; donde u cambia de frecuencia a lo largo del eje x,y v cambio de frecuencia a lo largo del eje y.</p>	
<p>Filtro gaussiano</p>	<p>La técnica de filtro gaussiano se implementa principalmente para suavizar imágenes, es decir, elimina el ruido presente en las imágenes sin eliminar completamente los bordes.</p>	<p>El filtro gaussiano básicamente consiste en una operación matemática que implementa una máscara o matriz, para recorrer una imagen, produciendo así otra imagen de salida más suavizada, con características de disminución en la nitidez, pérdida de detalles, entre otras. Este filtro es usado con el objetivo de aumentar o disminuir ciertas características.</p>	

Tabla 5. Tabla comparativa de las técnicas de inteligencia artificial. Fuente. Autoría propia.

Técnicas de inteligencia artificial

Técnica	Definición	Funcionamiento	Esquemático
Red neuronal multicapa	<p>Una red neuronal multicapa es una técnica que se basa en unir neuronas organizadas, que a su vez se encuentran distribuidas a lo largo de diferentes capas. Con este tipo de red se busca establecer una conexión entre un conjunto de entrada y un conjunto de salida.</p>	<p>Es un tipo de red de feedforward conformada inicialmente por una capa de entrada, un número de capas intermedias de proceso o capas ocultas según se requiera y finalmente otra capa de salida. Cada capa de entrada está conectada con la segunda capa, y cada capa oculta de la segunda capa está conectada con la primera capa y a su vez con la tercera capa. Por su parte la capa de salida está conectada únicamente con la última capa oculta.</p>	 <p>Capa de entrada Capas ocultas Capa de salida</p>
Red neuronal convolucional	<p>La red neuronal convolucional o CNN es un tipo de red artificial, cuya función se basa en procesar las capas que lo componen e identificar distintas características en la información de entrada. Su objetivo es extraer características, en este caso de una imagen. Estas redes consisten en un conjunto de filtros entrenables que efectúan un producto punto entre los valores de la capa actual y la capa anterior, el sistema aprende los valores y con esto puede reconocer ciertas características de las imágenes. Para lograr reconocer y diferenciar características, este tipo de redes están estructuradas por varias capas encargadas de identificar formas básicas, dichas capas se van especializando a medida que aumenta su profundidad, siendo las últimas capaces de reconocer formas complejas.</p>	<p>Las CNN modelan consecutivamente pequeñas secciones de información, para posteriormente combinarla entre las capas más profundas de la red neuronal. Básicamente, una convolución es un proceso que consiste en tomar un grupo de píxeles de la imagen original o de entrada para operar matemáticamente dicha información contra una pequeña matriz o kernel. El kernel se encarga de recorrer todas las neuronas de entrada en un orden de izquierda a derecha y posteriormente de arriba hacia abajo, con lo cual puede generar una nueva matriz de salida, que se convertirá en la nueva capa de neuronas ocultas o matriz de activación. La convolución solo se podrá realizar únicamente si el kernel es real y simétrico. Una forma de comprender cómo funciona esta técnica es teniendo en cuenta que esta red está compuesta inicialmente por una primera capa encargada de detectar bordes y establecer patrones para detectar bordes. Seguido a esto, las últimas capas combinarán la información en formas más simples y en patrones de las diferentes posiciones de los objetos como lo son la iluminación, escalas,</p>	 <p>Input 28x28 Feature maps 4x4x28x28 Feature maps 4x4x10x10 Feature maps 3x3x8x8 Feature maps 3x3x4x4 Output 20x1x1</p> <p>Convolution Subsampling Convolution Subsampling Convolution</p>

		<p>entre otros. Las capas finales intentarán hacer coincidir una imagen de entrada con todas los patrones desarrollados con el fin de realizar una predicción.</p>	
<p>Sistemas difusos</p>	<p>Esencialmente un sistema difuso es una teoría matemática de conjuntos clásicos basados en una lógica multivalente que permite tener valores intermedios y de esta manera tener la posibilidad de definir evaluaciones en tres categorías: sí/no, verdadero/falso, y negro/blanco. Posteriormente analiza la información que se encuentra en los intermedios de los extremos, así como la información que está fuera de los extremos y de los intermedios.</p>	<p>Los sistemas difusos están estructurados por conjuntos difusos, dichos conjuntos se encuentran definidos por unas reglas difusas, que permiten cuantificar la información en base a las reglas y a los mecanismos de inferencia que opera sobre los conjuntos con el fin de generar nuevos conjuntos difusos, es por esto que se hace necesario especificar cómo el sistema va a convertir la información de entrada a una información de tipo numérico, esto es conocido como “fuzzificación”. Así mismo, el proceso conocido como defuzzificación consiste en realizar un mapeo de un espacio de acciones de tipo difuso en acciones de tipo difuso. Esta técnica por tanto causa acción de control no difusa que se describe normalmente por la representación ycrisp.</p>	
<p>Inteligencia de enjambre</p>	<p>La Inteligencia de Enjambres (Swarm Intelligence, SI) es una técnica que analiza el comportamiento común de sistemas conformados por muchos individuos interactuando tanto localmente y como con su entorno, es decir, es un método que permite estudiar el comportamiento que tienen los sistemas autoorganizados y descentralizados. Los sistemas de SI pueden dividirse en un grupo de algoritmos, algunos grupos son: La Optimización basada en colonia de hormigas (ACO), La Optimización por Enjambre de Partículas (PSO) y en Optimización Por Enjambre de Bacterias (</p>	<p>Los sistemas de enjambre están compuestos generalmente por un conjunto de agentes computacionales simples encargados de percibir y modificar su ambiente localmente, lo que permite tener una comunicación entre los individuos encargados de detectar los cambios en el ambiente a causa del comportamiento de sus semejantes. En general los agentes están regidos por unas reglas simples de comportamiento y, aún cuando no posee una estructura de control centralizada que defina el comportamiento de los agentes individuales, las interacciones que se dan de forma local entre dichos agentes llevan a la emergencia de un comportamiento global y complejo.</p>	

	BSFO)		
Sistema inmune artificial	Es un algoritmo diseñado para producir nuevo conocimiento en forma de anticuerpos a partir de ejemplos limitados en cantidad los cuales toman el papel de antígenos. Este tipo de sistemas cumple con dos funciones básicas, una de reconocimiento y otra de eliminación de patógenos.	Primero se obtiene el antígeno, el cual es extraído por el sistema de aprendizaje por demostración que consiste en el guante de datos del cual se hablará en secciones posteriores. Toda la información obtenida por este sistema es el patógeno y cada uno de los datos es un antígeno, información que es entregada al proceso de clonación/mutación del algoritmo para de esta manera generar la diversidad para producir nuevos y diferentes datos (anticuerpos). Los ejemplos obtenidos son separados del arreglo y tratados según la variable a la que pertenezcan (posición y fuerza).	<p>El diagrama ilustra el proceso de selección de anticuerpos. Un antígeno (una estrella azul) se encuentra en el centro. Alrededor de él hay tres anticuerpos: anticuerpo B (una forma blanca con un hueco), anticuerpo A (una forma blanca con un hueco) y anticuerpo C (una forma blanca con un hueco). El anticuerpo A está etiquetado como 'clonación del anticuerpo A'. A la derecha, un grupo de anticuerpos mutados está etiquetado como 'mutación'.</p>

4.3 Selección de las técnicas.

Haciendo uso de la metodología PUGH, junto con la información recolectada se realizó el proceso de selección en base a los criterios de eficacia, duración de procesado (Tiempo de detección), precisión, complejidad y capacidad computacional requerida; como se muestra en la tabla (Ver tabla 6)

Tabla 6. Tabla resumen de los criterios y conceptos que se escogieron para la selección de las técnicas de inteligencia artificial. Fuente. Autoría propia.

Criterios	Conceptos					
	Referencia	Concepto 1	Concepto 2	Concepto 3	Concepto 4	Concepto 5
Criterio 1	-	1	1	0	1	0
Criterio 2	-	0	0	1	-1	-1
Criterio 3	-	0	1	0	1	0
Criterio 4	-	0	0	-1	0	-1
Criterio 5	-	1	1	1	1	c

Total (-)	0	0	-1	-1	-2
------------------	---	---	----	----	----

Total (+)	2	3	2	3	1
Total (Suma)	2	3	1	2	-1

Tabla 7. Tabla de los criterios de selección de las técnicas de inteligencia artificial. Fuente. Autoría propia.

Criterio 1	Eficacia
Criterio 2	Duración de procesado (Tiempo de detección)
Criterio 3	Precisión
Criterio 4	Complejidad
Criterio 5	Capacidad computacional requerida

Tabla 8. Tabla de los conceptos de selección de las técnicas de inteligencia artificial. Fuente. Autoría propia.

Concepto 1	Red neuronal multicapa
Concepto 2	Red neuronal convolucional
Concepto 3	Sistemas difusos
Concepto 4	Inteligencia de enjambre
Concepto 5	Sistema inmune artificial

Según el análisis realizado, la técnica de inteligencia artificial más adecuada a implementar para la clasificación de artefactos relacionados a la captura mamográfica es la técnica de redes neuronales convolucionales. En cuanto a las técnicas de procesamiento de imágenes biomédicas, si bien estas son considerablemente una gran cantidad, para esta aplicación únicamente nos centramos en las que son más comúnmente utilizadas por la comunidad científica para llevar a cabo el preprocesamiento de las imágenes de mamografía que posean artefactos relacionados a la captura, según lo encontrado en la bibliografía estudiada. Con lo cual se pudo determinar que lo más conveniente es implementar varias técnicas de procesamiento ya que al tratarse de distintos tipos de artefactos es necesario diseñar un protocolo de detección para cada artefacto, el cual se realizó con las siguientes técnicas de procesamiento:

- Binarización.

Esta técnica consiste en crear una imagen binaria al reemplazar todos los valores que se encuentran por encima de un umbral globalmente determinado por 1 y reemplazando todos los demás valores por 0. A continuación, se muestra la fórmula correspondiente:

$$dst(x, y) = \begin{cases} maxVal & \text{if } src(x,y) > thresh \\ 0 & \text{otherwise} \end{cases}$$

Ecuación 1

- Ajuste de contraste.

Es una técnica ampliamente utilizada con el fin de ajustar los valores de intensidad de una imagen o un mapa de colores, implementando la función *imadjust* se asignan valores de intensidad de I a nuevos valores de J.

- Filtro gaussiano.

Es una técnica de procesamiento de imágenes utilizado para eliminar el ruido presente en la imágenes al asignar un mayor peso al píxel central y a los píxeles que se encuentran cercano a este, y menor peso a los píxeles alejados. Esto se basa en la siguiente ecuación:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

Ecuación 3

- Filtro de dilatación.

Es una técnica de transformación morfológica que consiste en dilatar una imagen combinando dos conjuntos usando la suma vectorial de elementos de un conjunto como se ve en la ecuación 4, es decir se puede describir como un crecimiento de píxeles.

$$A \oplus B = \bigcup_{bc A} (A)_b$$

Ecuación 4

4.4 Diagrama de flujo.

Según las etapas consideradas en la metodología con el fin de segmentar paso a paso de manera general el funcionamiento del sistema de detección se desarrolló un diagrama de flujo (Ver Fig 5). Allí se incluyen las condiciones, procesos, entrada y salida de variable o información que se entregan durante todo el funcionamiento del sistema y que son necesarios conocer a la hora de desarrollar el algoritmo; iniciando con cargar, seleccionar y visualizar las imágenes con artefactos relacionados a la captura en formato DICOM, se prosigue a que el usuario inicie la aplicación del algoritmo de pre procesado de las imágenes e inteligencia para hacer la detección y clasificación de los artefactos para finalmente mostrar en la pantalla los resultados obtenidos y las imágenes superpuestas.

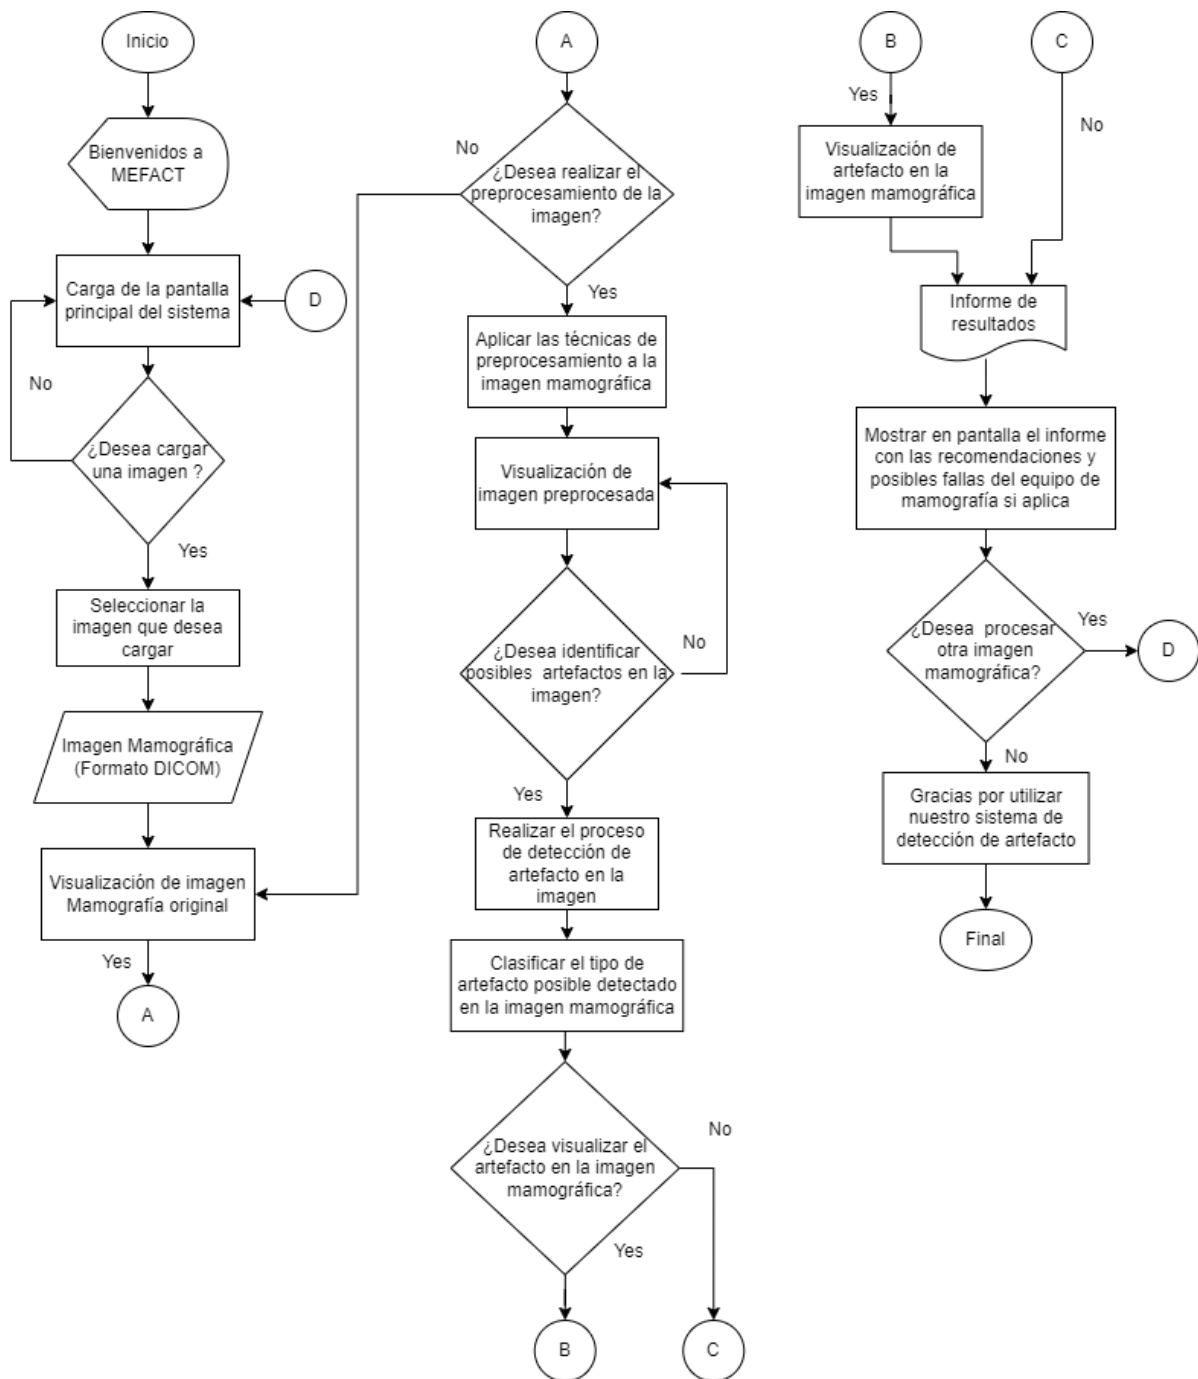


Fig 5. Diagrama de flujo de la metodología aplicada. Fuente. Autoría propia.

4.5 Software de Aplicación

El primer paso para el desarrollo del software de aplicación es la selección del lenguaje de programación, que como se expuso a lo largo del documento se realiza en el software de libre acceso Python dadas las ventajas que este conlleva, como lo son la gran variedad de librerías que hacen más sencillo la creación de algoritmos.

4.5.1 Procesamiento de imágenes.

El sistema de detección y clasificación de artefactos en imágenes mamográficas a causa de un fallo en el equipo, se divide principalmente en tres componentes. Primero, la etapa de procesamiento, la etapa de clasificación con inteligencia artificial y finalmente la interfaz de usuario. El procesamiento de la imágenes se hace con el fin de mejorar la calidad y facilitar la búsqueda de información, en este caso de los artefactos *Contrast Splatter*, pixel blanco y líneas radiolúcidas, cada una de estos es detectado con un protocolo de procesamiento diferente, según las características propias de cómo se visualiza el artefacto en la imagen.

El procesamiento del artefacto *Contrast Splatter* inicia al cargar la imagen, a la cual se le realizará un ajuste del contraste haciendo uso de la función *imadjust* con lo cual se logra saturar el 1 % inferior y el 1 % superior de todos los valores de los píxeles dando como resultado una imagen con un artefacto mucho más notorio. Finalmente se binariza la imagen para obtener una imagen en la que todo lo que esté por debajo de un valor umbral sea convertido en un 1 y lo que esté por encima de este valor sea convertido en 0. (Ver figura 6)




Fig 6. a) Imagen original con artefacto *contrast splatter*, b) Imagen del artefacto *contrast splatter* con ajuste de contraste, c) Imagen con artefacto *contrast splatter* binarizada. Fuente. Autoría propia.

Para procesar el artefacto pixel blanco se repite el proceso de cargar la imagen; dicha imagen será recorrida pixel por pixel y a medida de que este proceso se va ejecutando el algoritmo va identificando cambios abruptos en el valor de estos, es decir, detecta cambios de color en relación con sus píxeles vecinos. Posterior a la identificación de los mismos, se invierten los valores de cada pixel, ocasionando que los píxeles que tenían un color blanco cambien a color negro y a su vez los píxeles de color negro cambien a blanco. Para finalizar se implementa un filtro de dilatación a los píxeles de color negro con kernels de 3 x 3 con el propósito de aumentar su tamaño y que de esta manera sean visualizados más fácilmente. (Ver figura 7)




Fig 7. a) Imagen original con artefacto *pixel blanco* , b) Imagen del artefacto *pixel blanco* cambiando el color de los píxeles blancos a negros y los píxeles color negro a blanco, c) Imagen con artefacto *pixel blanco* implementando filtro de dilatación. Fuente. Autoría propia.

Por último, una vez sea seleccionada y cargada la imagen del artefacto de líneas radiolúcidas en la interfaz del sistema se continúa con la conversión de la imagen a escala de grises e implementado nuevamente la función `imadjust` se ajusta el contraste de la imagen buscando que el artefacto esté más definido. Luego, se aplica un filtro gaussiano de (11,11) a la imagen resultante haciendo uso de `(cv2.GaussianBlur)`, lo que causa que el valor máximo que hay el pixel central de una matriz vaya disminuyendo hacia los extremos dando como resultado un conjunto de valores entre 0 y 1, lo que se traduce en la imagen como un suavizado de las estructuras al eliminar el ruido de la misma. Como paso final se efectúa una resta de la imagen con el contraste ajustado y la imagen con el filtro gaussiano aplicado. (Ver figura 8)




Fig 8. a) Imagen original con artefacto *línea radiolúcida*, b) Imagen del artefacto *línea radiolúcida* ajustando el contraste, c) Imagen con artefacto *línea radiolúcida* implementando filtro gaussiano, d) Imagen del artefacto *línea radiolúcida* restando la imagen con el filtro gaussiano [c] con la imagen original [a]. Fuente. Autoría propia.

4.5.2 Algoritmo implementado.

El algoritmo de clasificación, se realizó a través del software libre Python, esta plataforma fue seleccionada ya que presenta un lenguaje multiplataforma de código abierto, es decir, presenta una gran cantidad de librerías y enlaces con otras plataformas de programación, donde despliega una gran posibilidad de estilos de programación, así como desarrollos de software y Aplicaciones.

La estructura funcional de la aplicación, se realizó usando como modelo la estructura propuesta en el diagrama de flujo (Ver figura 5) y para lograr cada una de las etapas se usaron las diferentes librerías que daban solución a los objetivos a alcanzar. A continuación, se mostrarán cada una de ellas:

Entorno de Aplicación:

- import PySimpleGUI as sg
- from tkinter import *
- from tkinter import messagebox as MessageBox

Selección y procesamiento de Imagen:

- import cv2
- import numpy as np

- import pydicom as dicom
- import matplotlib.pyplot as plt
- from skimage import io
- import os
- from scipy import ndimage
- CURR_DIR = os.getcwd()
- import imutils
- from PIL import Image
- from numpy.fft import fft2, fftshift, ifft2
- import pandas as pd
- import threading
- import zipfile

Librerías para proceso de inteligencia artificial:

- import tensorflow as tf
- from tensorflow import keras
- from tensorflow.keras import layers
- from tensorflow.keras.datasets import mnist
- from tensorflow.keras.utils import to_categorical
- import seaborn as sns

La estructura del algoritmo está organizada de la siguiente forma:

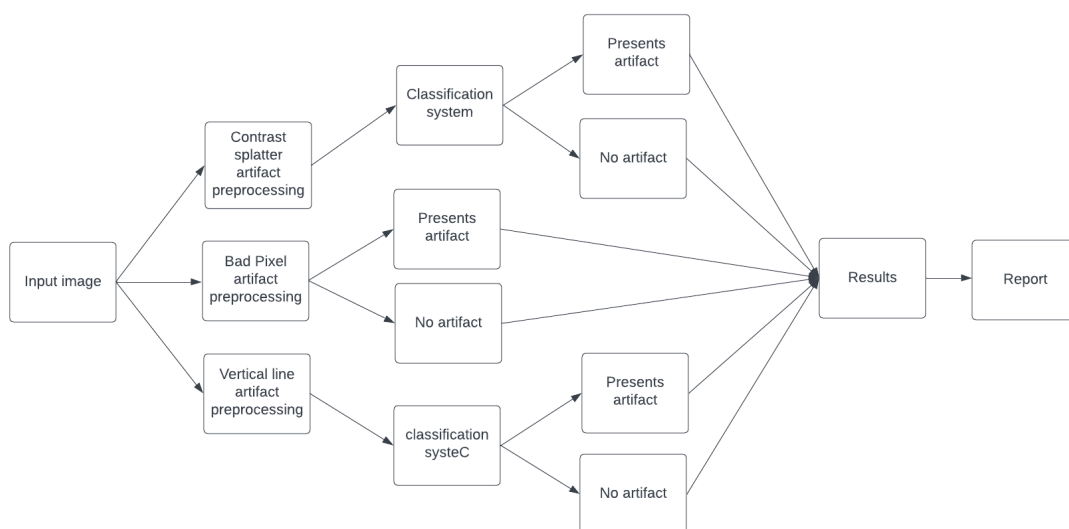


Fig 9. Organización del algoritmo. Fuente. Autoría propia.

El algoritmo de clasificación, se realizó teniendo como herramientas la base de datos de los 3 tipos de artefactos; este tipo de base de datos, no son muy comunes, por lo que se entrenó con pocas de ellas, de modo que se usó un algoritmo que aumenta el tamaño y cambia características, tales como movimiento de ancho, de alto y rango de rotación de las imágenes; todo esto, con el fin de que se puedan sumar a la base de datos de entrenamiento. A continuación, se muestra la cantidad de imágenes base que se tiene de cada artefacto:

Contrast splatter = 82.

Píxel defectuoso = 29.

Línea vertical =24.

Imágenes mamográficas normales = 128.

Dentro del algoritmo de clasificación para Contrast splatter y Línea vertical, se implementaron redes neuronales convolucionales esta presentaban las siguientes características:

```
tf.keras.layers.Conv2D(32, (3,3), activation='relu', input_shape=(100, 200, 1))
```

```
tf.keras.layers.MaxPooling2D(2, 2)
```

```
tf.keras.layers.Conv2D(62, (3,3), activation='relu')
```

```
tf.keras.layers.MaxPooling2D(2,2)
```

```
tf.keras.layers.Dropout(0.5)
```

```
tf.keras.layers.Flatten()
```

```
tf.keras.layers.Dense(100, activation='relu')
```

```
tf.keras.layers.Dense(2, activation="softmax")
```

El modelo de redes neuronales está conformado por 3 capas ocultas y una capa de salida, la primera capa oculta es de tipo convolucional, su *núcleo* o *Kernel* es una matriz de dimensión (3x3), la cual se empleó para la extracción de características de la imagen, y, esta capa presenta 32 neuronas de activación '*relu*'. La segunda capa oculta es de tipo convolucional, su *núcleo* o *Kernel* es una matriz de dimensión (3x3) y, ésta presenta 62 neuronas de activación '*relu*'. Para la tercera capa oculta, se tiene que ésta presenta 100 neuronas de activación '*relu*',

y finalmente, la capa de salida con activación "softmax" que es la encargada de dar la predicción, está compuesta por 2 neuronas.

Luego de diseñar la red neuronal, se realiza código de generación de imágenes con cambios de las siguientes características:

```
rango_rotacion = 30  
mov_ancho = 0.25  
mov_alto = 0.25  
rango_acercamiento=[0.5,1.5]
```

Los resultados obtenidos de la visualización de la base de datos correspondiente a las imágenes de Contrast splatter está en la Fig 10 , respecto a su etiqueta, los labels uno (1) corresponden a la presencia de artefactos, y los labels cero (0), corresponden a los que no presentan artefactos. Las imágenes mostradas en la Fig 11, corresponden a aquellas imágenes con artefacto de Contrast splatter generadas automáticamente cuyas características de rotación, movimiento, acercamiento, entre otros, se alteraron.

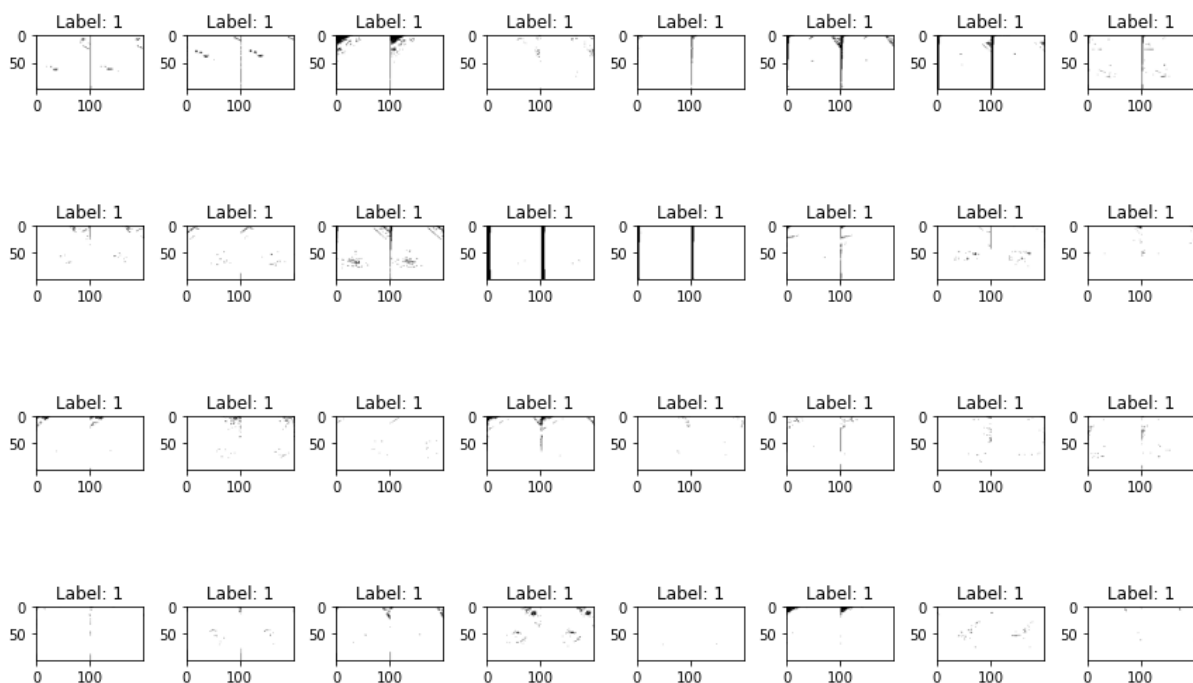


Fig 10. Resultados de las imágenes correspondientes a los artefactos de Contrast splatter. Fuente. Autoría propia.

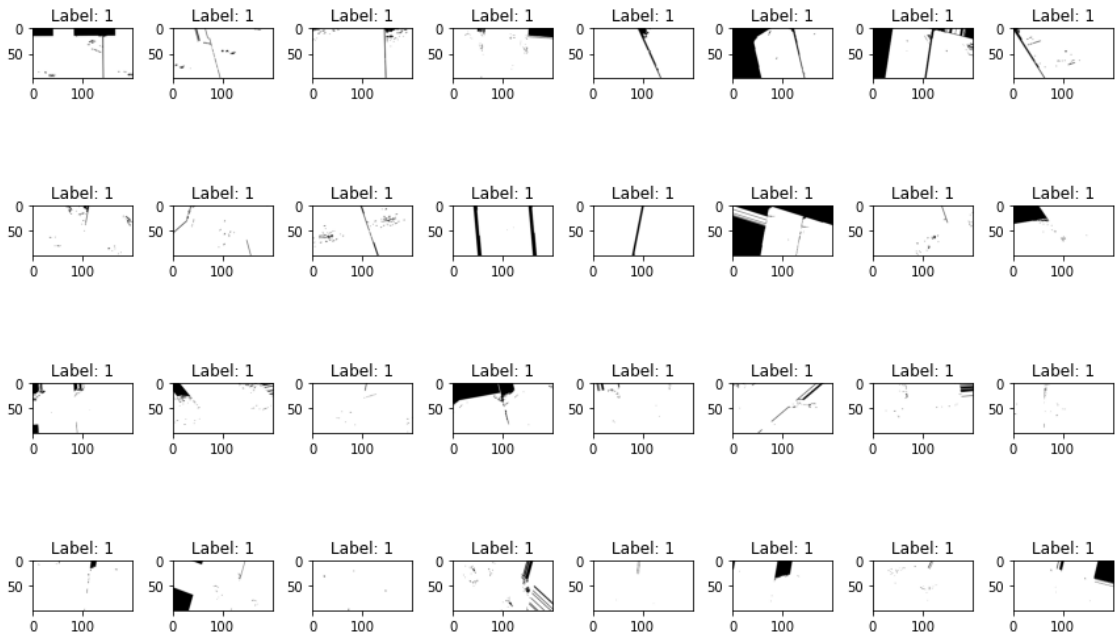


Fig 11. Resultados de las imágenes correspondientes a los artefactos de Contrast splatter después de realizar el cambio en las características. Fuente. Autoría propia.

La visualización de la base de datos correspondiente a las imágenes de Línea vertical, está en la Fig 12 , respecto a su etiqueta, los labels uno (1) corresponden a la presencia de artefactos, y los labels cero (0), corresponden a los que no presentan artefactos. Por otro lado, las imágenes mostradas en la Fig 13, corresponden a aquellas imágenes con artefacto de Línea vertical generadas automáticamente cuyas características de rotación, movimiento, acercamiento, entre otros, fueron alteradas.

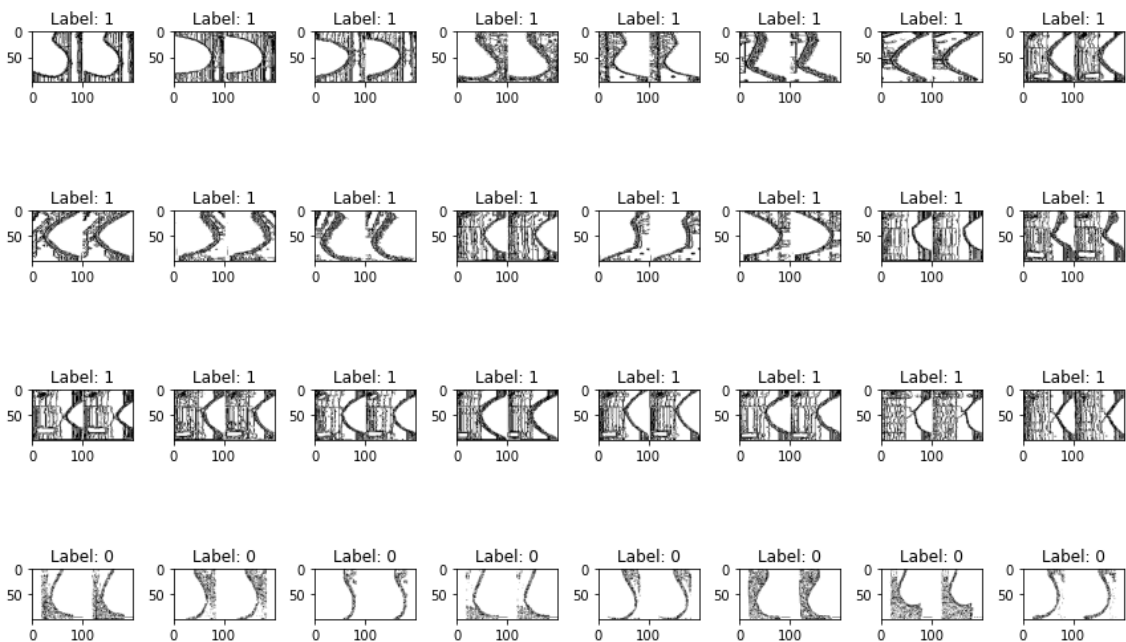


Fig 12. Resultados de las imágenes correspondientes a los artefactos de línea radiolúcida. Fuente. Autoría propia.

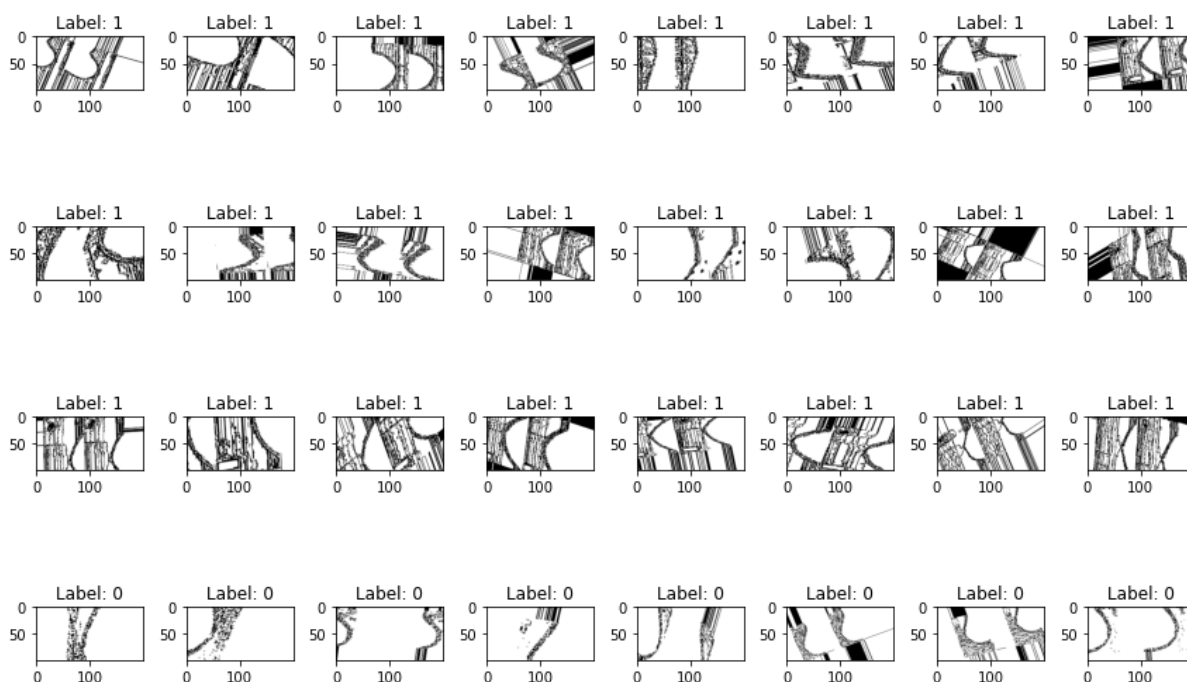


Fig 13. Resultados de las imágenes correspondientes a los artefactos de línea radiolúcida después de realizar el cambio en las características. Fuente. Autoría propia.

Teniendo en cuenta lo anterior, para el entrenamiento de la red neuronal de cada artefacto se distribuyó la base de datos de la siguiente manera: 70% Training y 30% Test. La Tabla 9 muestra la cantidad de imágenes usadas para el entrenamiento de la red neuronal de cada uno de los artefactos..

Tabla 9. Distribución de cantidad de imágenes implementadas para el entrenamiento de la red neuronal correspondiente a los artefactos de Contraste splatter y de Línea radiolúcida. Fuente. Autoría propia.

Artefacto	Cantidad de imágenes de base de datos		Cantidad de imágenes generadas.	Total de cantidad de imágenes para el entrenamiento de la red.
	Con artefacto	Sin artefacto		
Contrast splatter	58	100	632	790
Línea radiolúcida	17	100	468	585

Después de realizarle el entrenamiento a la red neuronal de tipo convolucional de 2 capas internas, con un ‘*epochs*’ correspondiente a 60 para el sistema de artefacto Contrast splatter y 200 para el sistema de artefacto de Línea vertical, la Tabla 10 muestra los resultados obtenidos de la red.

Tabla 10. Representación de los resultados obtenidos de las características del sistema de detección después de realizar el entrenamiento de la redes neuronales. Fuente. Autoría propia.

Sistemas de clasificación	loss	accuracy
Contrast splatter	11.5 %	88.5 %
Línea vertical	0.65 %	99.35 %

Cuando se realiza la predicción de una imagen en cualquiera de los 2 sistemas de clasificación, genera una matriz de 1x2, donde arroja dos “2” números, los cuales corresponden a grupo cero “0” o grupo uno “1”, lo que refleja si el artefacto está presente o no en la imagen, el cual se da a través de un dato en porcentaje, en donde si en el grupo cero “0” el número es mayor a 0.5 el artefacto no está. Mientras que, el número del grupo uno “1” será menor a 0.5, lo contrario sucedería, si el grupo cero “0” refleja un número menor a 0.5, y el grupo uno “1” presenta un número mayor a 0.5, significa que el artefacto está presente en la imagen.

Teniendo en cuenta la información anterior, los resultados obtenidos del entrenamiento de la red de detección de cada artefacto, se muestran en la matriz de confusión que muestra la Fig 14 y la Fig 15.




Fig 14. Matriz de confusión del entrenamiento y clasificación generado por la red neuronal de predicción del artefacto de Contrast splatter. Fuente. Autoría propia.




Fig 15. Matriz de confusión del entrenamiento y clasificación generado por la red neuronal de predicción del artefacto de Líneas verticales. Fuente. Autoría propia.

La matriz de confusión, refleja que para la clasificación de imágenes con presencia de artefacto de Contrast splatter, se obtuvo una buena predicción, en donde de 182 imágenes mamográficas con o sin artefacto, hubo correcta predicción en 161. En este sentido, el sistema se ve más afectado cuando las imágenes no presentan el artefacto que cuando presentan.

En cuanto a los resultados obtenidos, de la matriz de confusión de clasificación de imágenes con presencia de artefacto de Líneas verticales, se obtuvo que, de 154 imágenes mamográficas con y sin artefacto, 153 obtuvieron correcta predicción. De acuerdo a lo

anterior, el sistema se ve más afectado cuando las imágenes presentan el artefacto que cuando no presenta, aunque su porcentaje es considerablemente pequeño.

4.5.3 Diseño de la interfaz.

La presentación de la interfaz del software del sistema de detección y clasificación de artefactos, fue diseñada de manera sencilla de usar, siendo ésta una herramienta específica para detectar y clasificar artefactos. La aplicación se divide en:

- Cuadro de Introducción al programa.
- Menú principal de la aplicación.

Al iniciar el software aparece en pantalla una ventana de inicio en la que se presenta la aplicación. Ver figura 16.



Fig. 16. Ventana de inicio del “sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

Dicha ventana cuenta con logotipo diseñado específicamente para el sistema, ver figura. 17, nombre del software “Mefact”, nombre de la institución, nombre de los desarrolladores y su carrera universitaria. Adicionalmente, en el lateral derecho inferior, se encuentra un botón para redireccionar a una segunda ventana en donde se encuentra la pantalla principal.




Fig. 17. Logotipo del software “ Sistema para la detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

La ventana principal está conformada por el título ‘ARTEFACTOS DE IMÁGENES MAMOGRAFICAS’, seguido de la institución y Autores de ‘MEFACT’. Los botones presentes en la ventana, permitirán interactuar al usuario con la aplicación, desde el botón Buscar hasta la opción de impresión de informe. Para comenzar a identificar el artefacto, el usuario deberá seleccionar el botón Buscar. El panel de interacción, mostrará al usuario una guía de manejo rápido sobre el uso correcto de la aplicación y adicionalmente, la página de menú principal del software incluye tres recuadros en los cuales se pueden visualizar en primera instancia la imagen mamográfica original, en un segundo recuadro se puede observar la imagen procesada en donde se detecta y clasifica el artefacto, seguida de la imagen procesada y con el artefacto señalado superpuesta a la imagen original. Finalmente, un tercer recuadro de indicaciones de uso, que cumple la función de describir brevemente los pasos a seguir para utilizar la aplicación, el listado de cada uno de los elementos de control; allí también se puede visualizar un listado de las posibles causas de la aparición de estos artefactos en las imágenes. Asimismo, en este menú están incorporados los componentes barra de búsqueda, botones de control, recuadro de maximizar, minimizar y cerrar aplicación, botón de exportar datos e imágenes. Ver figura. 18.



Fig. 18. Ventana principal del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

- **Ventana de búsqueda**

La ventana de búsqueda se abrirá luego de seleccionar el botón buscar, lo que permitirá al usuario seleccionar la imagen, en la que se desea analizar el artefacto, en formato DICOM, y seguidamente, se seleccionará el botón Abrir. Ver figura. 19.

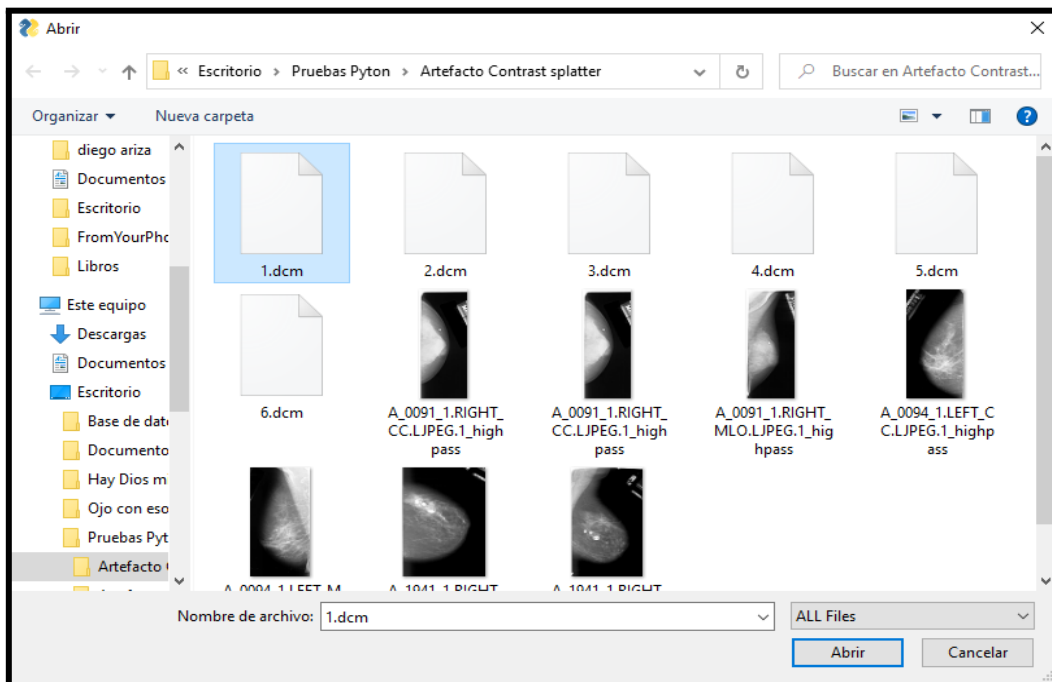


Fig. 19. Ventana de búsqueda de imágenes para entrenar el “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

Luego de seleccionar la imagen, la dirección de la misma se refleja en la barra de búsqueda de la ventana como se muestra a continuación. Ver figura. 20.



Fig. 20. Ubicación del archivo en la barra de búsqueda del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

Para la visualización de la imagen, se selecciona el botón Mostrar imagen original, y a continuación se mostrará en el primer panel de imagen de la aplicación. Ver figura 21.



Fig. 21. Visualización de la imagen original del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

Al seleccionar el botón identificar artefacto, se clasificará el artefacto presente en la imagen, y si ésta no se presenta artefacto, también se informará. Los resultados se reflejarán en el panel de interacción de usuario y se podrán desplazar las imágenes que muestran los artefactos, este desplazamiento está dado por los botones como se muestra en la Fig. 22. Es preciso mencionar, que estos botones están habilitados siempre y cuando exista más de un artefacto en la imagen mamográfica.



Fig. 22. Visualización de la imagen con el artefacto clasificado del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

Al seleccionar ‘Visualización de artefacto’, se mostrará en el segundo panel de imagen de la aplicación, en formato binario, como lo muestran las siguientes imágenes. Ver figura 23, figura 24 y figura 25.



Fig. 23. Visualización de la imagen binaria con el artefacto clasificado del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.



Fig. 24. Visualización de la imagen binaria con el artefacto clasificado del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.



Fig. 25. Visualización de la imagen binaria con el artefacto clasificado del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

Después de visualizar el artefacto, el usuario puede verlo señalado en la imagen original seleccionando el botón ‘Visualización de artefacto superpuesto’, como se muestra a continuación. Ver figura 26, figura 27 y figura 28.



Fig. 26. Visualización artefacto superpuesto “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.



Fig 27. Visualización artefacto superpuesto“Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.



Fig. 28. Visualización artefacto superpuesto“Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

El botón de informe, permitirá la visualización de la descripción del artefacto, características y posibles causas relacionadas al equipo de mamografía, todo este informe se podrá visualizar

en el panel de interacción de usuario, como se muestra a continuación. Ver figura 29 y figura 30.



Fig. 29. Visualización de informe de resultados “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.



Fig. 30. Visualización de informe de resultados “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

Por último el botón de Reiniciar datos, permite reiniciar los paneles de imagen e interacción, para el análisis de una imagen mamográfica nueva. Ver figura 31.



Fig. 31. Reinicio de datos del “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

4.6 Pruebas de funcionamiento del sistema.

Las pruebas de funcionamiento del sistema se dividen en dos secciones; la primera consiste en utilizar 50 imágenes de diferentes dimensiones con el fin de verificar que cada una de las herramientas que componen el aplicativo funcione correctamente. Esto se realizó para comprobar que las imágenes se carguen, visualicen y procesen sin inconvenientes, como se detalla en la Tabla 11.

Tabla 11. Tabla de resultados de funcionamiento del sistema. Fuente. Autoría propia.

Tabla de resultado				
Pruebas de funcionamiento			N° de imágenes usadas	50
Tipo de prueba	Características	Resultado de prueba		Resultados
		Correcta	Incorrecta	
Selección y visualización de la imagen original	Se tomaron imágenes al azar de la base de datos de diferentes dimensiones	50	0	El sistema cargó y se visualizaron correctamente todas las imágenes.

	para la prueba.			
Identificación de artefactos	Se tomaron imágenes al azar de la base de datos de diferentes dimensiones para la prueba.	50	0	El sistema realizó clasificación a todas las imágenes cargadas.
Visualización de los resultados de clasificación e informe	Se tomaron imágenes al azar de la base de datos de diferentes dimensiones para la prueba.	50	0	El sistema generó correctamente los resultados de la clasificación, según la presencia de artefactos.

La segunda sección de las pruebas de funcionamiento es con el fin de determinar si el aplicativo clasifica o no correctamente y consiste en cargar un banco de imágenes con artefactos e imágenes sin artefactos. Mediante la fórmula matemática de Murray y Larry se determinó que un tamaño muestral representativo de 45, es decir, que las mamografías uno de los tres tipos de artefactos y la mamografías sin artefactos deben procesarse en el software 45 imágenes diferentes (Ver ecuación 5).

$$n = \frac{Z_a^2 * N * p * q}{i^2 (N-1) + Z_a^2 * p * q}$$

Ecuación 5

Donde:

n = Tamaño de la muestra.

Z = valor correspondiente a la distribución de gauss, $z\alpha = 0.05 = 1.96$ y $z\alpha = 0.01 = 2.58$.

p = Proporción de la población sin la característica deseada.

q = Proporción de la población deseada.

i = Margen de error.

$$n = \frac{1.96^2 * 83 * 0.5 * 0.5}{0,1^2 (83-1) + 1.96^2 * 0.5 * 0.5}$$

$$n = 44.7726$$

$$n \approx 45$$

4.7 Pruebas de funcionamiento del sistema de clasificación.

Los resultados obtenidos en las pruebas de funcionamiento del sistema de detección y clasificación de artefactos asociados a la captura de imágenes mamográficas se organizan en las siguientes tablas para el artefacto de *Contrast Splatter* (Ver tabla 12), artefacto de pixel blanco (Ver tabla 13), artefacto de línea radiolúcida (Ver tabla 14), y mamografías sin artefactos (Ver tabla 15).

Tabla 12. Tabla de resultados de las pruebas de funcionamiento de detección y clasificación de artefactos *Contrast Splatter*. Fuente. Autoría propia.

Número de muestras	Categoría	Artefacto <i>Contrast Splatter</i>
1	Artefacto de <i>Contrast Splatter</i>	0.999983
2	Artefacto de <i>Contrast Splatter</i>	1.000000
3	Artefacto de <i>Contrast Splatter</i>	1.000000
4	Artefacto de <i>Contrast Splatter</i>	0.999961
5	Artefacto de <i>Contrast Splatter</i>	1.000000
6	Artefacto de <i>Contrast Splatter</i>	1.000000
7	Artefacto de <i>Contrast Splatter</i>	1.000000
8	Artefacto de <i>Contrast Splatter</i>	1.000000
9	Artefacto de <i>Contrast Splatter</i>	0.999999
10	Artefacto de <i>Contrast Splatter</i>	0.999998
11	Artefacto de <i>Contrast Splatter</i>	0.999946
12	Artefacto de <i>Contrast Splatter</i>	0.999992
13	Artefacto de <i>Contrast Splatter</i>	1.000000
14	Artefacto de <i>Contrast Splatter</i>	1.000000
15	Artefacto de <i>Contrast Splatter</i>	1.000000
16	Artefacto de <i>Contrast Splatter</i>	1.000000
17	Artefacto de <i>Contrast Splatter</i>	1.000000
18	Artefacto de <i>Contrast Splatter</i>	1.000000
19	Artefacto de <i>Contrast Splatter</i>	0.999967
20	Artefacto de <i>Contrast Splatter</i>	0.999719
21	Artefacto de <i>Contrast Splatter</i>	1.000000
22	Artefacto de <i>Contrast Splatter</i>	1.000000

23	Artefacto de <i>Contrast Splatter</i>	1.000000
24	Artefacto de <i>Contrast Splatter</i>	1.000000
25	Artefacto de <i>Contrast Splatter</i>	0.999882
26	Artefacto de <i>Contrast Splatter</i>	1.000000
27	Artefacto de <i>Contrast Splatter</i>	1.000000
28	Artefacto de <i>Contrast Splatter</i>	1.000000
29	Artefacto de <i>Contrast Splatter</i>	0.999897
30	Artefacto de <i>Contrast Splatter</i>	0.999996
31	Artefacto de <i>Contrast Splatter</i>	0.999892
32	Artefacto de <i>Contrast Splatter</i>	0.999981
33	Artefacto de <i>Contrast Splatter</i>	1.000000
34	Artefacto de <i>Contrast Splatter</i>	1.000000
35	Artefacto de <i>Contrast Splatter</i>	0.999994
36	Artefacto de <i>Contrast Splatter</i>	1.000000
37	Artefacto de <i>Contrast Splatter</i>	0.922297
38	Artefacto de <i>Contrast Splatter</i>	0.999211
39	Artefacto de <i>Contrast Splatter</i>	0.0611179
40	Artefacto de <i>Contrast Splatter</i>	0.999996
41	Artefacto de <i>Contrast Splatter</i>	0.999952
42	Artefacto de <i>Contrast Splatter</i>	0.999999
43	Artefacto de <i>Contrast Splatter</i>	0.997694
44	Artefacto de <i>Contrast Splatter</i>	0.999996
45	Artefacto de <i>Contrast Splatter</i>	1

Tabla 13. Tabla de resultados de las pruebas de funcionamiento de detección y clasificación de artefactos pixel blanco. Fuente. Autoría propia.

Número de muestras	Categoría	Artefacto de pixel blanco
1	Artefacto de puntos blancos	1
2	Artefacto de puntos blancos	1
3	Artefacto de puntos blancos	1
4	Artefacto de puntos blancos	1
5	Artefacto de puntos blancos	1
6	Artefacto de puntos blancos	1
7	Artefacto de puntos blancos	1
8	Artefacto de puntos blancos	1
9	Artefacto de puntos blancos	1

10	Artefacto de puntos blancos	1
11	Artefacto de puntos blancos	1
12	Artefacto de puntos blancos	1
13	Artefacto de puntos blancos	1
14	Artefacto de puntos blancos	1
15	Artefacto de puntos blancos	1
16	Artefacto de puntos blancos	1
17	Artefacto de puntos blancos	1
18	Artefacto de puntos blancos	1
19	Artefacto de puntos blancos	1
20	Artefacto de puntos blancos	1
21	Artefacto de puntos blancos	1
22	Artefacto de puntos blancos	1
23	Artefacto de puntos blancos	1
24	Artefacto de puntos blancos	1
25	Artefacto de puntos blancos	1
26	Artefacto de puntos blancos	1
27	Artefacto de puntos blancos	1
28	Artefacto de puntos blancos	1
29	Artefacto de puntos blancos	1
30	Artefacto de puntos blancos	1
31	Artefacto de puntos blancos	1
32	Artefacto de puntos blancos	1
33	Artefacto de puntos blancos	1
34	Artefacto de puntos blancos	1
35	Artefacto de puntos blancos	1
36	Artefacto de puntos blancos	1
37	Artefacto de puntos blancos	1
38	Artefacto de puntos blancos	1
39	Artefacto de puntos blancos	1
40	Artefacto de puntos blancos	1
41	Artefacto de puntos blancos	1
42	Artefacto de puntos blancos	1
43	Artefacto de puntos blancos	1
44	Artefacto de puntos blancos	1
45	Artefacto de puntos blancos	1

Tabla 14. Tabla de resultados de las pruebas de funcionamiento de detección y clasificación de artefactos línea radiolúcida. Fuente. Autoría propia.

Número de muestras	Categoría	Artefacto de línea radiolúcida
1	Artefacto de línea radiolúcida	0.942497
2	Artefacto de línea radiolúcida	0.995389
3	Artefacto de línea radiolúcida	0.992581
4	Artefacto de línea radiolúcida	0.559073
5	Artefacto de línea radiolúcida	0.970317
6	Artefacto de línea radiolúcida	0.992809
7	Artefacto de línea radiolúcida	0.998568
8	Artefacto de línea radiolúcida	0.999434
9	Artefacto de línea radiolúcida	0.997434
10	Artefacto de línea radiolúcida	0.867866
11	Artefacto de línea radiolúcida	0.92921
12	Artefacto de línea radiolúcida	0.999182
13	Artefacto de línea radiolúcida	0.358497
14	Artefacto de línea radiolúcida	0.931807
15	Artefacto de línea radiolúcida	0.99977
16	Artefacto de línea radiolúcida	0.998466
17	Artefacto de línea radiolúcida	0.999819
18	Artefacto de línea radiolúcida	0.998839
19	Artefacto de línea radiolúcida	0.9995
20	Artefacto de línea radiolúcida	0.999143
21	Artefacto de línea radiolúcida	0.999466
22	Artefacto de línea radiolúcida	0.998964
23	Artefacto de línea radiolúcida	0.997927
24	Artefacto de línea radiolúcida	0.999384
25	Artefacto de línea radiolúcida	0.969781
26	Artefacto de línea radiolúcida	0.998461
27	Artefacto de línea radiolúcida	0.925661
28	Artefacto de línea radiolúcida	0.977885
29	Artefacto de línea radiolúcida	0.996947
30	Artefacto de línea radiolúcida	0.997059
31	Artefacto de línea radiolúcida	0.964535
32	Artefacto de línea radiolúcida	0.996108
33	Artefacto de línea radiolúcida	0.996118

Número de muestras	Categoría	Artefacto de línea radiolúcida
1	Artefacto de línea radiolúcida	0.942497
2	Artefacto de línea radiolúcida	0.995389
3	Artefacto de línea radiolúcida	0.992581
4	Artefacto de línea radiolúcida	0.559073
34	Artefacto de línea radiolúcida	0.711338
35	Artefacto de línea radiolúcida	0.575368
36	Artefacto de línea radiolúcida	0.998736
37	Artefacto de línea radiolúcida	0.982193
38	Artefacto de línea radiolúcida	0.999488
39	Artefacto de línea radiolúcida	0.992266
40	Artefacto de línea radiolúcida	0.998205
41	Artefacto de línea radiolúcida	0.000000
42	Artefacto de línea radiolúcida	0.998615
43	Artefacto de línea radiolúcida	0.823683
44	Artefacto de línea radiolúcida	0.995958
45	Artefacto de línea radiolúcida	0.999264

Tabla 15. Tabla de resultados de las pruebas de funcionamiento de detección y clasificación de imágenes sin artefactos. Fuente. Autoría propia.

Número de muestras	Categoría	Sin artefacto
1	Imagen normal	0
2	Imagen normal	0
3	Imagen normal	0
4	Imagen normal	0
5	Imagen normal	0
6	Imagen normal	0
7	Imagen normal	0
8	Imagen normal	0
9	Imagen normal	0
10	Imagen normal	0
11	Imagen normal	0
12	Imagen normal	0
13	Imagen normal	0
14	Imagen normal	0
15	Imagen normal	0

16	Imagen normal	0
17	Imagen normal	0
18	Imagen normal	0
19	Imagen normal	0
20	Imagen normal	0
21	Imagen normal	0
22	Imagen normal	0
23	Imagen normal	0
24	Imagen normal	0
25	Imagen normal	0
26	Imagen normal	0
27	Imagen normal	0
28	Imagen normal	0
29	Imagen normal	0
30	Imagen normal	0
31	Imagen normal	0
32	Imagen normal	0
33	Imagen normal	0
34	Imagen normal	0
35	Imagen normal	0
36	Imagen normal	0
37	Imagen normal	0
38	Imagen normal	0
39	Imagen normal	0
40	Imagen normal	0
41	Imagen normal	0
42	Imagen normal	0
43	Imagen normal	0
44	Imagen normal	0
45	Imagen normal	0

Con el fin de evidenciar todos los valores obtenidos, en las tablas 12, 13, 14 y 15, están los valores de las pruebas iniciales con las imágenes mamográficas en formato DICOM. Estas pruebas se realizaron con imágenes que presentaban artefactos e imágenes mamográficas normales, este proceso se repite con 45 imágenes para las imágenes con *Contrast Splatter*, pixel blanco, líneas radiolúcidas y/o imágenes normales, adicionalmente la tabla contiene un

valor que va de 0 a 1 y que representa la probabilidad de que la imagen contenga ese artefacto.

El sistema de detección y clasificación de imágenes desarrollado permite visualizar la imagen mamográfica original que debe ser procesada, también permite visualizar la identificación del artefacto *Contrast Splatter* como se observa en la Fig. 32, la identificación del artefacto de pixel blanco como se observa en la Fig. 33 y el artefacto de líneas radiolúcidas como se observa en la Fig. 34. Adicionalmente, presenta en uno de los recuadros la clasificación de cada uno de los artefactos que presenta la imagen y un informe final de las posibles causas que ocasionan la aparición de estos en las mamografías. Ver figura 32, figura 33 y figura 34.

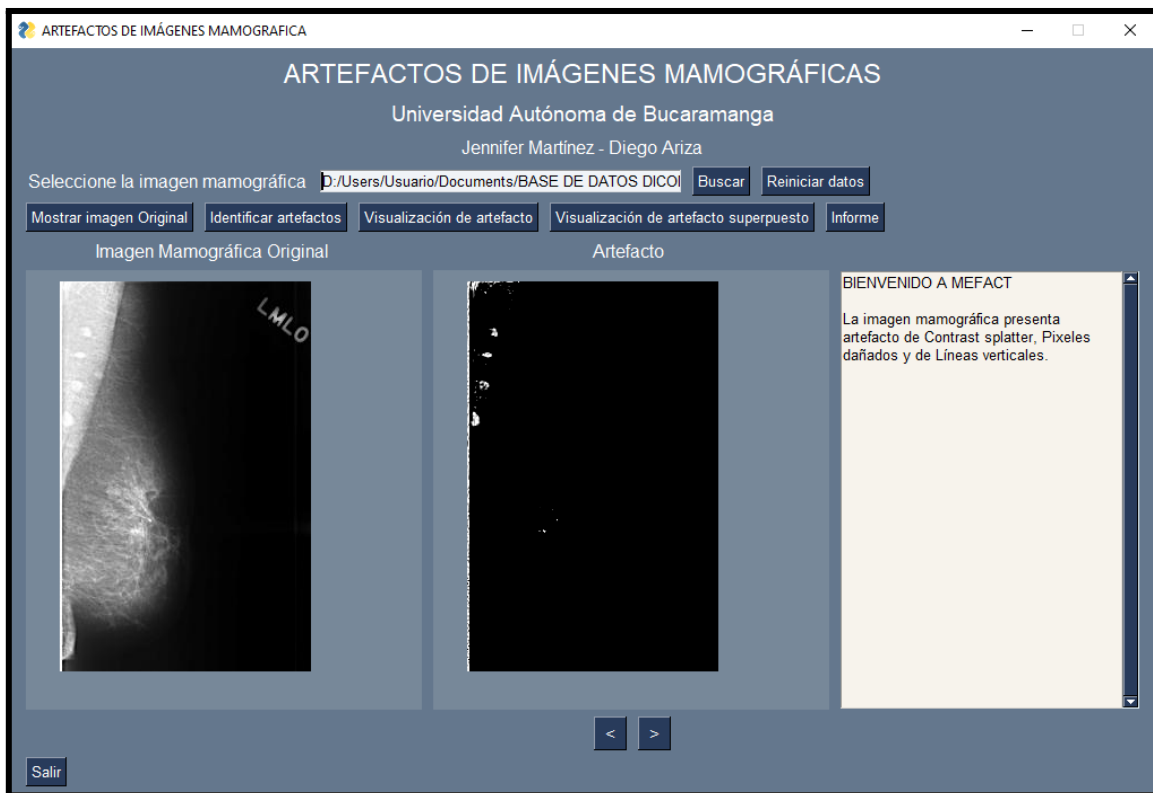


Fig. 32. Visualización artefacto *Contrast Splatter* “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

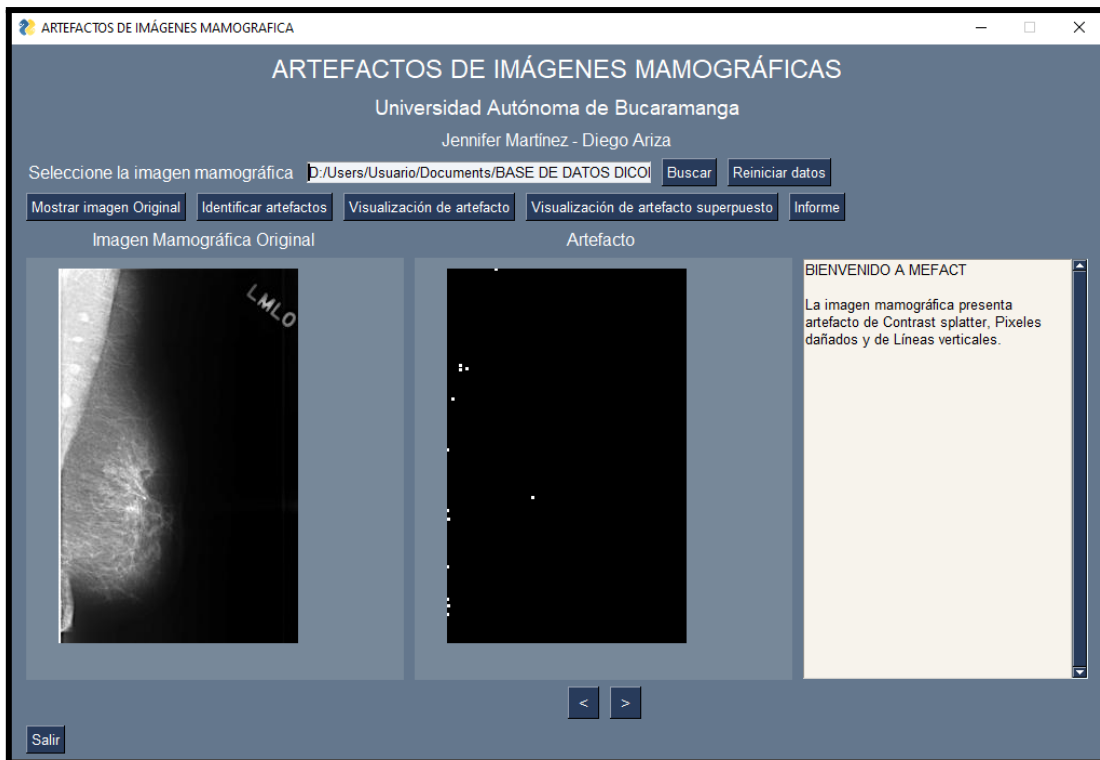


Fig. 33. Visualización artefacto Pixel blanco “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.



Fig. 34. Visualización artefacto Líneas radiolúcidas “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

El aplicativo también brinda la opción de visualizar las imágenes procesadas y con el artefacto identificado bien sea como *Contrast Splatter*, (Ver figura 35), pixel blanco, (Ver figura 36) y el artefacto de líneas radiolúcidas ver figura 37 y figura 38, superpuestas sobre la imagen original.

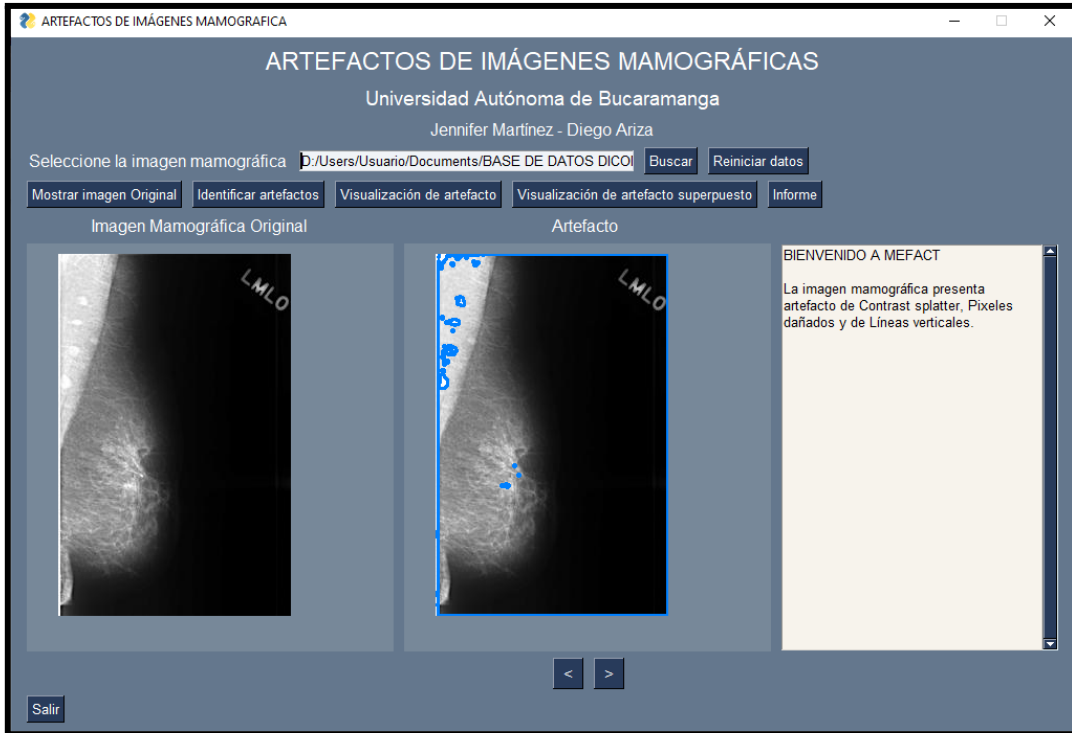


Fig. 35. Visualización artefacto *Contrast Splatter* superpuesto "Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas". Fuente. Autoría propia.



Fig. 36. Visualización artefacto Pixel blanco superpuesto “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.



Fig. 37. Visualización artefacto superpuesto “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.



Fig. 38. Visualización artefacto Líneas radiolúcidas superpuesto “Sistema de detección y clasificación de artefactos asociados a las imágenes mamográficas”. Fuente. Autoría propia.

4.8 Análisis estadístico.

Para la validación de los resultados obtenidos de las pruebas de funcionamiento del sistema de detección y clasificación de artefactos en imágenes mamográficas se realizó la siguiente tabla (Ver tabla 16).

Tabla 16. Valores de media aritmética y desviación estándar de la clasificación del sistema de cada uno de los grupos muestrales. Fuente. Autoría propia.

Tabla del análisis estadístico de los grupos de estudio						
Artefacto Grupo	Contrast Splatter		píxeles blancos		líneas radiolúcidas	
	Media aritmética	Desviación estándar	Media aritmética	Desviación estándar	Media aritmética	Desviación estándar
Imagen con píxeles blancos	0.958828466	0.1510718500	1	0	0.8944531222	0.2116482026
Imagen sin artefactos	0.209162462	0.2181043331	0	0	0.1450266882	0.2999552570
Imagen con Contrast Splatter	0.977321553	0.1401621934	1	0	0.7073263555	0.3517103625
Imagen con líneas radiolúcidas	0.919070219	0.2495788808	0.9777777777	0.1490711984	0.9205246888	0.1940318938

Según los datos de la Tabla 16, se definen para cada caso planteado los valores de media y desviación estándar para los datos correspondientes a: artefacto de *Contrast Splatter*, artefacto de líneas radiolúcidas, artefacto de pixel blanco e imágenes sin artefacto. Posteriormente, se realiza una prueba T (Ver tabla 17) , dándonos como resultado valor T para cada uno de los grupos a los que se aplicó, dichos valores indican que cada grupo proviene de una población diferente. Por otro parte, la prueba ANOVA (Ver tabla 18) arroja un valor p, y se establece que siempre que el valor sea menor a 0.01 el nivel de significancia no es relevante, indicando que los grupos pertenecen a poblaciones diferentes. En el caso contrario, cuando este valor es mayor a 0.01 el nivel de significancia es relevante de modo que los grupos poseen las mismas características.

Tabla 17. Tabla prueba T para cada grupo de estudio. Fuente. Autoría propia.

Pruebas estadísticas T Tests		
Valor P (Imagen con artefacto de Contrast Splatter vs Imagen sin artefactos)	Valor P (Imagen con artefacto de píxeles blancos vs Imagen sin artefactos)	Valor P (Imagen con artefacto de líneas radiolúcidas vs Imagen sin artefactos)

8.07x10-33	2.71x10-34	8.42x10-25
------------	------------	------------

Tabla 18. Tabla prueba ANOVA para cada grupo de estudio. Fuente. Autoría propia.

Pruebas estadísticas ANOVA					
Imagen con artefacto de Contrast Splatter vs Imagen sin artefactos		Imagen con artefacto de pixeles blancos vs Imagen sin artefactos		Imagen con artefacto de líneas radiolúcidas vs Imagen sin artefactos	
Valor F	Valor P	Valor F	Valor P	Valor F	Valor P
4.14 x 10+2	5.08x10-24	3.71 × 10+2	4.4543x10-23	1.64 × 10+2	1.85x10-16

Finalmente, se realiza un gráfico de cajas y bigotes en donde se evalúan los valores para los tres casos, el primero es el referente a las imágenes mamográficas con artefacto de *Contrast Splatter* contra los valores obtenidos para las imágenes sin artefactos (Ver figura 39), el segundo corresponde a los valores de las imágenes mamográficas con artefacto de líneas radiolúcidas contra los valores obtenidos para las imágenes sin artefactos (Ver figura 40) y el último caso de los valores de las imágenes mamográficas con artefacto de pixel blanco contra los valores obtenidos para las imágenes sin artefactos (Ver figura 41).

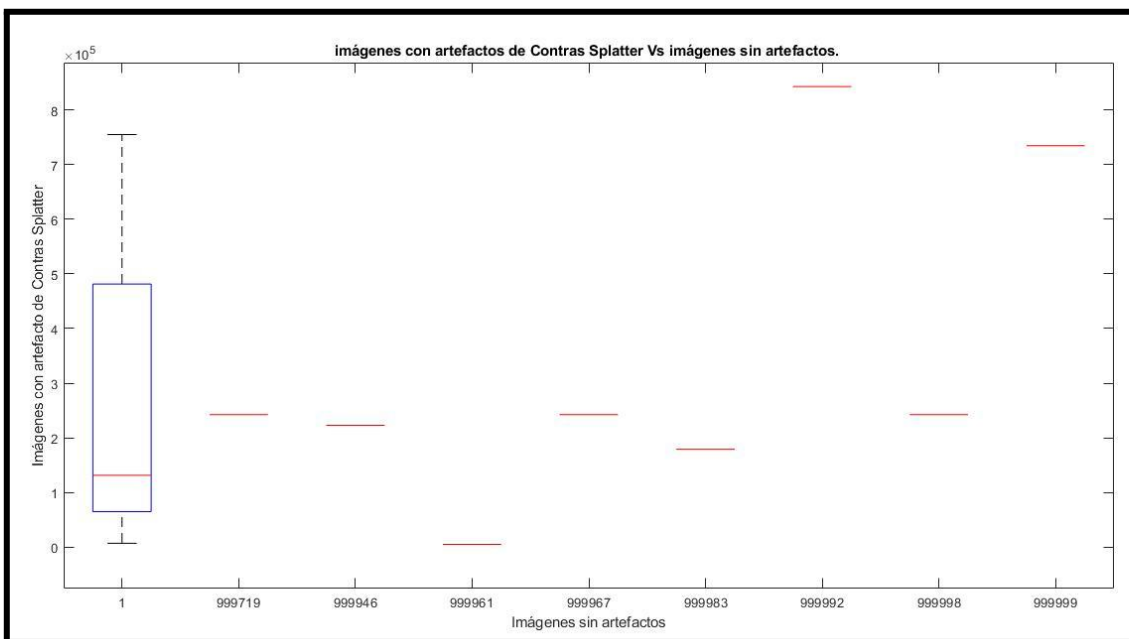


Fig 39. Gráfico de cajas resultados de imágenes con artefactos de *Contrast Splatter* Vs imágenes sin artefactos. Fuente. Autoría propia.

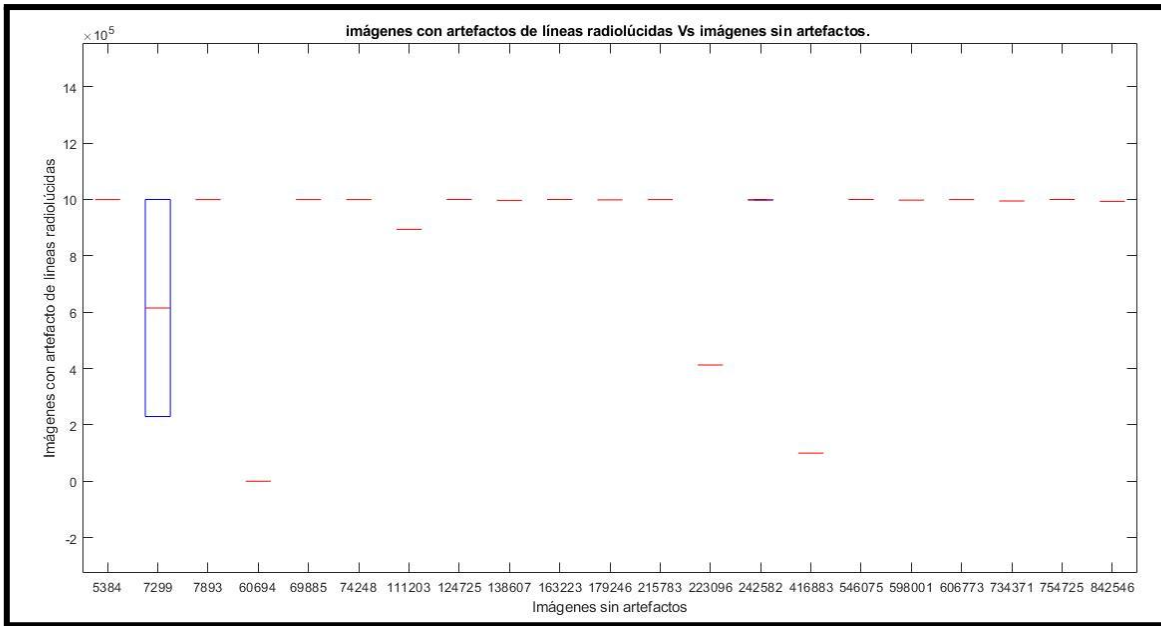


Fig 40. Gráfico de cajas resultados de imágenes con artefactos de líneas radiolúcidas Vs imágenes sin artefactos.
Fuente. Autoría propia.

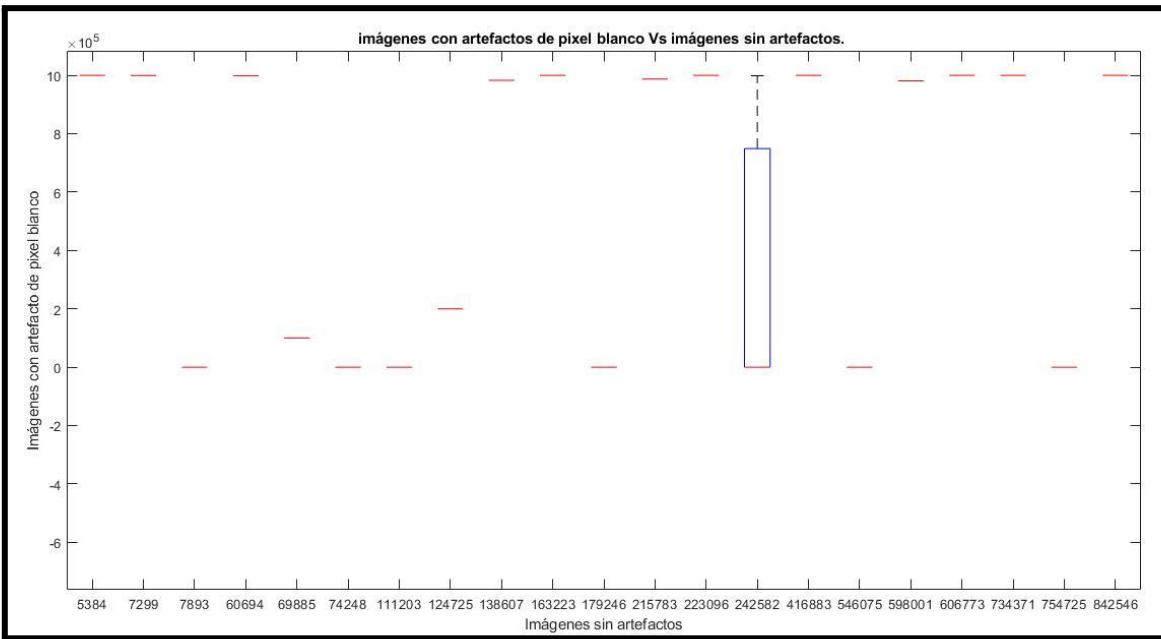


Fig 41. Gráfico de cajas resultados de imágenes con artefactos de pixel blanco Vs imágenes sin artefactos.
Fuente. Autoría propia.

Capítulo V

Análisis de resultados

5.1 Análisis de resultados de la investigación de las diferentes técnicas de procesamiento de imagen e inteligencia artificial.

Cada una de las técnicas investigadas corresponden a técnicas de procesamiento de imágenes, pero no específicamente para imágenes médicas, como en este caso mamográficas. Estas técnicas fueron adaptadas, con el fin de usarlas en artefactos de imágenes, por ello se realizaron varias pruebas para verificar cual de las técnicas de procesamientos permitía la visualización del artefacto en específico. En la actualidad, existen procedimientos para la detección de masas o estructuras calcificadas en imágenes mamográficas, pero muy poco para la aplicación en artefactos en imágenes.

Las técnicas de procesamiento de imágenes, que ayudaron a la revelación de artefacto en imágenes mamográficas fueron, Filtrado basado en píxeles y Filtro de dilatación, usado para artefacto de píxeles dañados; Ecuilización del histograma, Negativo de una imagen, Realzado de bordes y Binarización, usado para artefacto de Contrast Platter; Filtro Pasa altas, Transformada de fourier y Filtro Gaussiano, usado para artefacto de líneas verticales. Finalmente, para una mejor visualización de artefactos, se utilizó la técnica de contorno, en conjunto con la técnica de binarización.

Las técnicas de Inteligencia artificial consultadas, como Red neuronal multicapa, Red neuronal convolucional, Sistemas difusos, Inteligencia de enjambre y Sistema inmune artificial; permiten el entrenamiento de un sistema de clasificación de imágenes, algunas de estas técnicas presentan afinidad con cierto tipo de imágenes, y varían en su capacidad de clasificación y consumo computacional.

5.2 Análisis de resultados de la comparación de las técnicas de procesamiento de imágenes e inteligencia artificial.

Para poder desarrollar un sistema que detectara, clasificara artefactos correctamente y los diferenciara de imágenes sin artefactos, inicialmente fue de suma importancia realizar una investigación sobre cada una de las técnicas de procesamiento de imágenes e inteligencia

artificial usadas más comúnmente en estudios similares al nuestro. Luego de leer, analizar y comprender literatura sobre cada técnica se plasmó la información más relevante en la Tabla 4, para el caso de las técnicas de procesamiento de imágenes y la tabla 5, para las técnicas de inteligencia artificial, permitiéndonos realizar un comparativo de pros y contras de las características de cada una de las técnicas detalladas, con el fin de seleccionar la más óptima en el caso de inteligencia artificial, y la selección de las técnicas necesarias procesar lo máximo posible de manera general los artefactos según la morfología de cada uno, para de esta manera lograr la detección de los artefactos dentro de la imagen.

5.3 Selección de las técnicas.

La Tabla 6, expone las características de las técnicas de inteligencia artificial llamados conceptos, frente a los criterios, la técnica seleccionada fue redes neuronales convolucionales, ya que este tipo de redes presenta alta eficacia y precisión, no es compleja y no requiere de gran capacidad computacional para su entrenamiento, la plataforma escogida para su programación es python. Estas redes convolucionales, se caracterizan por no solo tomar como referencia de aprendizaje un patrón de imágenes.

Las redes neuronales convolucionales, tienen una alta eficiencia en clasificación de características ya que esta técnica consiste en el análisis de los valores de píxeles junto a los píxeles vecinos, y mide o detecta cualquier cambio en sus tonalidades, estas redes extraen características de las imágenes y las aprende, en relación a la estructura de la imagen y objeto de interés, a diferencia de las redes neuronales regulares, clasifica bien una imagen siempre y cuando la imagen que se le realizará predicción sea muy parecida a la de las imágenes del set de datos con fue entrenada la red. Si por alguna razón la imagen se mueve, rota o cambia de tamaño su región de interés pueda que su clasificación se vea considerablemente afectada, ya que su forma de análisis es a nivel de píxel sin tener en cuenta los píxeles vecinos, y estos ofrecen mucha información de características específicas de una imagen sobre un objeto de interés.

Las técnicas de procesamiento de imágenes seleccionadas, cumplen un papel fundamental al momento de resaltar los artefactos, para usarlas en el sistema de clasificación de artefactos y para la visualización de las mismas, ya que el sistema de clasificación tiene como entrada mamografías preprocesadas, imágenes binarizadas. Los filtros de contraste, permiten resaltar un rango de contraste teniendo como referencia la Histograma de la imagen mamográfica, y

atenúa los otros rangos, este es usado para el artefacto de Contrast Platter y de línea vertical. El filtro gaussiano es usado en el artefacto de línea vertical para la detección de cambios de pigmentación secuencialmente verticales, el filtro de dilatación se usa para el artefacto de píxeles dañados para visualizar mejor la ubicación de los píxeles dañados en la imagen.

5.4 Análisis de resultados de diagrama de flujo.

El diagrama de flujo que muestra la Fig 5, presenta y describe una correcta secuencia de funcionamiento del sistema de clasificación donde se asegurará que el usuario realice correctamente los pasos para la obtención de los resultados.

5.5 Análisis de resultados de procesamiento de imágenes.

El procesamiento de imágenes se realizó de forma secuencial, donde cada imagen de entrada es procesada para los 3 artefactos, los resultados obtenidos fueron satisfactorios, ya que el procesamiento del artefacto de Contrast Platter, permitía la visualización del artefacto correctamente a través la función *imadjust*, para luego realizar binarización e implementar el sistema de clasificación. El procesamiento de la imagen con artefacto de Línea vertical revela las líneas translúcidas que caracteriza la presencia del artefacto, usando el *filtro gaussiano* en la imagen mamográfica, unas de las dificultades que se obtuvieron es la visualización del borde de la mama de la imagen mamográfica procesada, pero la diferencia de los resultados del procesamiento entre una imagen con artefacto y otra que no, es muy significativa, por lo que se usó este método y el sistema de detección reconoce satisfactoriamente la diferencia.

5.6 Análisis de resultados de algoritmo implementado.

Teniendo en cuenta los resultados obtenidos del algoritmo implementado en el entrenamiento de la red neuronal (Ver Tabla 6), se puede afirmar que los resultados esperados de Accuracy de los modelos entrenados están dentro del rango esperado; sin embargo este valor puede mejorar mucho más. La base de datos seleccionada para el entrenamiento de la red, presenta un tamaño pequeño de imágenes mamográficas con artefactos, unos de estos artefactos estaban etiquetados en la descripción de la imagen mamográfica y otro se seleccionó por similitudes en el tipo de artefacto que presentaba, en este caso se reunieron las categorías de mamografías con artefactos de tipo Contrast splatter, Píxel defectuoso, Línea vertical e imágenes mamográficas sin artefactos. Dentro de la investigación, si se hubiese realizado el

entrenamiento de red con una cantidad mucho mayor de imágenes mamográficas con artefactos, el sistema de clasificación aumentaría su Accuracy para muchas más imágenes.

La programación del sistema de clasificación se realizó en Python, ya que este software permitía realizar diseños y entrenamiento de redes neuronales y de tipo convolucionales. El diseño de estas redes se realizó con capas ocultas convolucionales con su *núcleo* o *Kernel* de dimensiones (3x3) la cual se empleó para la extracción de características de la imagen, y, esta capa presenta 32 neuronas de activación '*relu*'. La segunda capa oculta es de tipo convolucional, su *núcleo* o *Kernel* es una matriz de dimensión (3x3) y, ésta presenta 62 neuronas de activación '*relu*'. La tercera capa oculta, esta presenta 100 neuronas de activación '*relu*', y finalmente, la capa de salida con activación "*softmax*" que es la encargada de dar la predicción, está compuesta por 2 neuronas. Esta configuración presentó uno de los mejores resultados en la clasificación de las imágenes con artefactos.

Para resolver el problema de la poca cantidad de imágenes mamográficas se lleva a cabo la utilización de código de aumento de datos, en este caso, aumento de imágenes mamográficas, realizando cambios en las imágenes de la base de datos, estos cambios se realizaron en características de rotación, movimiento en ancho, movimiento de alto y rango de acercamiento con el fin de incrementar las imágenes usadas en el entrenamiento, este aumento lo realiza automáticamente el código internamente.

Teniendo en cuenta la matriz de confusión de los resultados de clasificación del entrenamiento realizado, se obtuvieron buenos resultados, a pesar de la cantidad de imágenes usadas para el entrenamiento, ya que para la clasificación de imágenes con presencia de artefacto de Contrast splatter, 88.46 % de ellas fueron correctamente clasificadas y para la clasificación de imágenes con presencia de artefacto de Líneas verticales, se obtuvo un porcentaje de 99.35 % en imágenes correctamente clasificadas.

5.7 Análisis de resultados de Diseño de la interfaz.

El diseño de la interfaz fue realizado en el entorno de programación Python por su diversificación de funciones, modelos de diseño y características de interacción con el usuario que permitía. El diseño MEFACT cumple con el objetivo de ser sencillo y fácil de operar por el usuario, cumple con un funcionamiento secuencial de operación, para que el usuario se le facilite en lo absoluto la utilización de la aplicación. El sistema MEFACT tiene un sistema de mensajes de alerta que advierten al usuario frente cualquier movimiento o

selección que no cumple con la secuencia de funcionamiento, además, indica el paso faltante que debe realizar el usuario para obtener un resultado apropiado.

La aplicación presenta un panel de interacción con el usuario, con el objetivo de dar indicaciones de uso y brindar información de resultados de los diferentes procesos que se den en el aplicativo. El panel de interacción de inicio muestra una pequeña guía rápida para que el usuario pueda conocer la función de cada botón de la App, durante la ejecución del mismo el panel mostrará información de la clasificación y el informe del mismo de los resultados para que el usuario pueda tomar indicaciones.

5.8 Análisis de resultados de pruebas de funcionamiento del sistema.

Los valores de las columnas 3, 4 y 5 de la tabla 12 corresponden a la probabilidad de que una imagen contenga un artefacto de *Contrast Splatter*, pixel blanco y líneas radiolúcidas respectivamente y para cada uno de los casos, permitiendo de esta manera analizar en base a estos datos si el software de aplicación está realizando correctamente el proceso de detección y clasificación de artefactos en imágenes mamográficas en formato DICOM.

Dado que para la clasificación de los artefactos de *Contrast Splatter* y líneas radiolúcidas se implementó la técnica de inteligencia artificial de redes neuronales convolucionales, el aplicativo arroja dos tablas para cada uno de los dos artefactos, cada tabla está compuesta por dos columnas que corresponden a la clase cero (0) y a la clase uno (1), las cuales dan como resultado para cada una un valor entre cero (0) y uno (1) como se ve en la figura 42; siendo la clase 0 la que hace referencia a imágenes sin artefactos y la clase 1 a imágenes con artefactos.

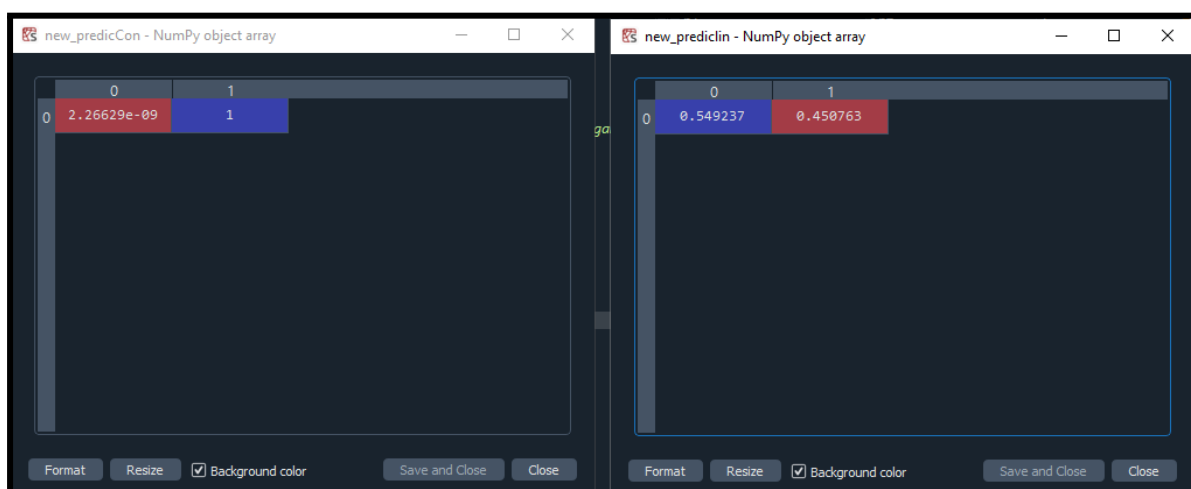


Fig 42. a) Tabla de clasificación artefacto de *Contrast Splatter* con clase 0 y clase 1; b) Tabla de clasificación artefacto de pixel blanco con clase 0 y clase 1. Fuente. Autoría propia.

En este caso en específico se tomó únicamente el valor de la clase 1 ya que la detección y clasificación está enfocada a artefactos, por lo que si el valor de la clase 1 es mayor a 0.5 el sistema clasifica a la imagen según el artefacto que se haya identificado, por ejemplo, según los valores visualizados en la figura 42, la imagen contiene un artefacto de *Contrast Splatter* pero no uno de líneas radiolúcidas. Para el caso de que la imagen no presente ningún artefacto el valor de la clase 1 debe ser inferior a 0.5, lo que indicaría que las coincidencias de la morfología del artefacto en la imagen son muy bajas o nulas.

Este proceso se realizó con 180 imágenes en total, y como se puede observar en los valores de las tablas 12,13,14 y 15 el sistema clasifica las imágenes que contiene artefactos de las que no tienen artefactos correctamente, ya que del banco total de imágenes 45 pertenecían a imágenes sin artefactos, de las cuales, las 45 dieron un valor inferior a 0.5, en cada una de ellas para cada uno de los artefactos.

5.9 Análisis de resultados estadísticos.

Como se puede observar en la tabla 17, los datos obtenidos al aplicar una prueba T con distribución de 2 colas para los valores que arroja el sistema realizando las siguientes comparaciones: primero, el caso de imágenes con artefacto de *Contrast Splatter* contra imagen sin artefactos, segundo, el caso de imágenes con artefacto de líneas radiolúcidas contra imágenes sin artefactos y tercero el caso imágenes con artefacto de píxeles blancos contra imágenes sin artefactos, mostrando un p-valor para cada uno de los casos de 8.0712×10^{-33} , 8.42×10^{-25} , 2.7087×10^{-34} respectivamente, con el cual se puede inferir que las 45 imágenes de cada grupo no provienen de la misma población, por lo que se rechaza la hipótesis y se garantiza que el sistema desarrollado reconoce con un margen de error bajo.

Por otro lado, el análisis de la varianza o prueba ANOVA permite comparar los valores de varianza existentes entre distribuciones de los resultados obtenidos en las tablas 12,13,14 y 15 para las 45 imágenes que componen cada grupo de estudio: el caso de imágenes con artefacto de *Contrast Splatter* contra imagen sin artefactos, el caso de imágenes con artefacto de líneas radiolúcidas contra imágenes sin artefactos y finalmente el caso imágenes con artefacto de píxeles blancos contra imágenes sin artefactos. Al ser el p-valor para cada grupo de 5.0778×10^{-24} , 4.4543×10^{-23} , 1.85×10^{-12} respectivamente, se puede inferir que el nivel

de significancia no es relevante, por ende, cada grupo proviene de una población diferente, es decir, cada grupo representa un tipo de artefacto diferente.

Capítulo VI

Conclusiones y recomendaciones

En el presente capítulo se exponen las conclusiones obtenidas en el proceso de planteamiento, desarrollo y análisis del proyecto. Adicionalmente se dan algunas recomendaciones en caso de que se desee realizar mejoras y/o trabajos relacionados en un futuro.

6.1 Conclusiones.

El presente proyecto se llevó a cabo con el objetivo de diseñar un sistema para la detección y clasificación de artefactos asociados a las imágenes mamográficas y evaluar la eficiencia y confiabilidad del software desarrollado, para lograr esto fue fundamental la realización de una investigación exhaustiva sobre las distintas técnicas tanto de procesamiento de imágenes, como de inteligencia artificial. Una vez plasmada y organizada esta información, y haciendo uso del método PUGH, se seleccionaron las técnicas más adecuadas para llevar a cabo este estudio. Las técnicas seleccionadas permitieron albergar buenos resultados en la visualización de la imagen original y el artefacto presente en la imagen a través de las etapas de preprocesamiento diseñado; la técnica de inteligencia artificial seleccionada “*Redes neuronales convolucionales*” permitió el entrenamiento de la red y predicción de las imágenes mamográfica con resultados aceptables como se muestra en la Tabla 10 Fig. 14 y Fig. 15, con valores de accuracy para el artefacto de *Contrast Splatter* de 88.5 % y un accuracy de para el artefacto de líneas radiolúcidas de 99.35 % respectivamente. Por otro lado, la interfaz de usuario diseñada presenta características de selección de imagen, clasificación de artefacto y visualización de la misma, a través de un sistema secuencial y sencillo de operar por el usuario, dicho sistema fue elaborado en el software libre *Python*, obteniendo así resultados satisfactorios como los muestra el ítem de Diseño de la interfaz en el capítulo de resultados. Por último, el diseño y ejecución de las pruebas de funcionalidad aplicada a la interfaz MEFACT, pudieron mostrar resultados del estado de funcionamiento de la aplicación, y poder así realizar cambios pertinentes, con el objetivo de mejorarla y presentarla. Teniendo en cuenta todo lo anterior, se puede concluir que la metodología planteada y ejecutada fue exitosa y permitió cumplir los objetivos propuestos.

Así mismo, la interfaz diseñada permite cumplir a cabalidad la operatividad del sistema en cuanto a detección y clasificación al brindar la opción de visualizar no solo el artefacto por sí mismo, sino también el artefacto superpuesto sobre la imagen original, facilitando así para los profesionales de la salud el estudio de estas imágenes y no retrasar los diagnósticos y tratamientos. También, ayuda a mejorar los estándares de calidad de las mamografías al proporcionar a los profesionales encargados de los mantenimiento preventivos y/o correctivos de los equipos de mamografías de las instituciones de salud la información sobre el tipo de artefacto y las posibles causas que generan estos artefactos y poder solventar estos fallos.

Sin embargo, teniendo en cuenta los resultados obtenidos a pesar del tamaño de la base de datos, si se aumentara la cantidad de datos de imágenes para el entrenamiento de la red neuronal, se estaría llegando a un sistema mucho más confiable y exacto en su clasificación. La aplicación MEFACT, es una aplicación moldeable, es decir, es sensible a cualquier tipo de modificación, con lo cual, al implementar en un futuro una base de datos más completa y robusta para el entrenamiento de la red neuronal, se podría mejorar la clasificación de artefacto en las imágenes mamográficas .

6.2 Recomendaciones

El proceso de detección y clasificación de artefactos realizado por el software de aplicación, se vio limitado para su entrenamiento y elaboración debido a la dificultad de acceder a una base de datos lo suficientemente robusta y que contenga una mayor cantidad de tipos de artefactos a los tratados en este estudio. Por lo tanto, existe la necesidad y la oportunidad de mejorar y ampliar bases de datos a través de investigaciones específicas de cada artefacto, ya que un solo tipo de artefacto puede presentar diferentes características, formando así, subclases del mismo. Al usar una base de datos robusta para el entrenamiento de la red neuronal, se garantiza resultados de eficiencia y confiabilidad considerablemente altos.

Capítulo VII

Bibliografía

Aguirre Dobernack, N. (2021). *PROCESAMIENTO DE IMÁGENES* [Ebook] (p. Cap 3). Fecha de Consulta: 2 de septiembre de 2021. Disponible en: http://bibing.us.es/proyectos/abreproy/12112/fichero/Documento_por_capitulos%252F3_Cap%C3%ADtulo_3.pdf.

Barr, H., Blanco, S. A. A., Butler, P., da Paz, M. A., Fleitas, I., Craig, G., . . . Swann, P. (2016). *Mammography Services Quality Assurance: Baseline Standards for Latin America and the Caribbean*. Web

Clinical Implication, Dr. Laszlo Tabar (Ed.), ISBN: 978-953-51-0284-7, InTech. Fecha de Consulta: 2 de septiembre de 2021. Disponible en: <http://www.intechopen.com/books/imaging-of-the-breasttechnical-aspects-and-clinical-implication/quality-requirements-of-image-in-digital-mammography-for-breastcancer-screening>

Costa Campos, A., & Fernández Bozal, J. (2005). La imagen digital. Fecha de Consulta: 2 de septiembre de 2021. Disponible en: https://www.revistadeortodoncia.com/files/2005_35_3_255-266.pdf

Departamento Administrativo Nacional de Estadística, DANE. Índice de mortalidad por cáncer de mama. Fecha de consulta: 15 de agosto de 2021. Disponible en: <http://www.dane.gov.co/index.php/estadisticas-por-tema/salud/nacimientos-y-defunciones/defunciones-no-fetales/defunciones-no-fetales-2016>

Enterprise, H. (2021). *¿Qué es la inteligencia artificial? – Definiciones de TI empresarial*. Hpe.com. Fecha de Consulta: 2 de septiembre de 2021. Disponible en: <https://www.hpe.com/lamerica/es/what-is/artificial-intelligence.html>.

García KJ, Ocampo JD, Pardo M del P, Aguilar T, Ruiz CA, Castaño A. Calidad de las imágenes, la lectura y el servicio de mamografía en cuatro centros de imagenología de

Manizales, Colombia. biomédica. Fecha de consulta: 15 de agosto de 2021 ;41(1):52-4. Disponible en: <https://revistabiomedica.org/index.php/biomedica/article/view/5135>

Globocan GC. Estimated number of incident cases worldwide, females, all ages. Fecha de consulta: 15 de agosto de 2021. Disponible en: http://gco.iarc.fr/today/online-analysis-multi-bars?v=2018&mode=cancer&mode_population=countries&population=900&populations=484&key=total&sex=0&cancer=39&type=0&statis=5&prevalence=0&population_group=0&ages_group%5B%5D=0&ages_group%5B%5D=17&nb_items=10

Guertin, M. H., Théberge, I., Zomahoun, H., Dufresne, M. P., Pelletier, É., & Brisson, J. (2018). Mammography Clinical Image Quality and the False Positive Rate in a Canadian Breast Cancer Screening Program. *Canadian Association of Radiologists journal = Journal l'Association canadienne des radiologistes*, 69(2), 169–175. Fecha de consulta: 15 de agosto de 2021. Disponible en: <https://doi.org/10.1016/j.carj.2017.12.003>

Gómez, D. V; Guerrero, A (2016). Estudio y análisis de técnicas para procesamiento digital de imágenes. Fecha de Consulta: 2 de septiembre de 2021. Disponible en: <http://repositorio.utp.edu.co/dspace/handle/11059/6494>

Hellquist, B. N., Duffy, S. W., Abdsaleh, S., Björnelid, L., Bordás, P., Tabár, L., Viták, B., Zackrisson, S., Nyström, L., & Jonsson, H. (2011). Effectiveness of population-based service screening with mammography for women ages 40 to 49 years: evaluation of the Swedish Mammography Screening in Young Women (SCRY) cohort. *Cancer*, 117(4), 714–722. Fecha de consulta: 15 de agosto de 2021. Disponible en: <https://doi.org/10.1002/cncr.25650>

Kendall, E.J., Barnett, M.G. & Chytyk-Praznik, K. (2013). Automatic detection of anomalies in screening mammograms. *BMC Med Imaging* 13, 43 . Fecha de Consulta: 2 de septiembre de 2021. Disponible en: <https://doi.org/10.1186/1471-2342-13-43>

Ley estatutaria 1581 (2012). Fecha de Consulta: 14 de octubre de 2021. Disponible en: http://www.secretariasenado.gov.co/senado/basedoc/ley_1581_2012.html

Ley 23 “Sobre derechos de autor” (1983). Fecha de Consulta: 14 de octubre de 2021. Disponible en: <http://derechodeautor.gov.co:8080/documents/10181/182597/23.pdf/a97b8750-8451-4529-ab87-bb82160dd226>

Margarita Chevalier, Fernando Leyton, Maria Nogueira Tavares, Marcio Oliveira, Teogenes A. da Silva and João Emilio Peixoto (2012). Image Quality Requirements for Digital Mammography in Breast Cancer Screening, Imaging of the Breast - Technical Aspects and

Mamografia.(ACR), R. (2021). Fecha de consulta: 28 de Octubre de 2021, Disponible en: <https://www.radiologyinfo.org/es/info/mammo>

Palomino, N.L., & Concha, U.R. (2014). Técnicas de Segmentación en Procesamiento Digital de Imágenes. Fecha de Consulta: 2 de septiembre de 2021. Disponible en: <https://www.semanticscholar.org/paper/T%C3%A9cnicas-de-Segmentaci%C3%B3n-en-Procesamiento-Digital-Palomino-Concha/199c8cac02503a705bf2005e3353539750f4e7ee>

Patiño, P., Hernández Restrepo, M. and Ortega Santamaría, J., 2013. Devices in Digital Mammography. 3764-70. Fecha de consulta: 15 de agosto de 2021. Disponible en: http://contenido.acronline.org/Publicaciones/RCR/RCR24-3/07_Artefactos%20en%20mamograf%C3%ADa.pdf

Pérez, P., & Valente., M. (2018). *Fundamentos básicos del procesamiento de imágenes — documentación de Curso de imágenes médicas - 1.0*. Famaf.unc.edu.ar. Fecha de Consulta: 2 de septiembre de 2021. Disponible en: <https://www.famaf.unc.edu.ar/~pperez1/manuales/cim/cap2.html>.

¿Qué es una mamografía?. (2021). Fecha de consulta: 15 de agosto de 2021, Disponible en: https://www.cdc.gov/spanish/cancer/breast/basic_info/mammograms.htm

Resolución 8430 (1993). Fecha de Consulta: 14 de octubre de 2021. Disponible en: <https://www.minsalud.gov.co/sites/rid/Lists/BibliotecaDigital/RIDE/DE/DIJ/RESOLUCION-8430-DE-1993.PDF>

Ribli, D., Horváth, A., Unger, Z. *et al.* (2018). Detecting and classifying lesions in mammograms with Deep Learning. *Sci Rep* 8, 4165. Fecha de Consulta: 2 de septiembre de 2021. Disponible en: <https://doi.org/10.1038/s41598-018-22437-z>

Sartori, P., & Rozowykniat, M., & Siviero, L., & Barba, G., & Peña, A., & Mayol, N., & Acosta, D., & Castro, J., & Ortiz, A. (2015). Artefactos y artificios frecuentes en tomografía computada y resonancia magnética. *Revista Argentina de Radiología*, 79(4),192-204. Fecha de Consulta: 24 de agosto de 2021. ISSN: 1852-9992. Disponible en: <https://www.redalyc.org/articulo.oa?id=382543178003>

Santo da Anunciação Zage, P. (2017). *Comparación de Calidad de Imagen en Mamografía con contraste de fase Vs Mamografía digital usando un maniquí antropomórfico*. Fecha de Consulta: 22 November 2021, Disponible en: <https://dspace.uclv.edu.cu/bitstream/handle/123456789/8520/Tesis%20Santo%20Pedro.pdf?sequence=1&isAllowed=y>

Vega Jaramillo, A. (2010). Manual de derecho de autor. Fecha de Consulta: 14 de octubre de 2021. Disponible en: <http://derechodeautor.gov.co:8080/documents/10181/331998/Cartilla+derecho+de+autor+%28Alfredo+Vega%29.pdf/e99b0ea4-5c06-4529-ae7a-152616083d40>