



DETECCIÓN DE CÁNCER DE MAMA A PARTIR DE IMÁGENES HISTOPATOLÓGICAS Y DE MAMOGRAFÍAS MEDIANTE REDES NEURONALES Y SEGMENTACIÓN DE IMÁGENES

Trabajo de grado para optar al título de Ingeniero Electrónico

Trabajo de Grado

Autor:

Heider Rey Hernandez Arpushana

Tutor/es:

MSc. Luis Alberto Muñoz Bedoya

17 de diciembre de 2022

DETECCIÓN DE CÁNCER DE MAMA A PARTIR DE IMÁGENES HISTOPATOLÓGICAS Y DE MAMOGRAFÍAS MEDIANTE REDES NEURONALES Y SEGMENTACIÓN DE IMÁGENES

Trabajo de grado Ingeniería Electrónica

Autor

Heider Rey Hernandez Arpushana

Tutor/es

MSc. Luis Alberto Muñoz Bedoya
Universidad de Pamplona



Trabajo de grado para optar al título de Ingeniero Electrónico

Pamplona, 17 de diciembre de 2022

Dedico este trabajo a...

A mi mama, Ruby Arpushana y a mi papa Sebastián Hernandez por ser esas personas que siempre me brindaron todo su amor. A mi abuelo Reinaldo Hernandez por brindarme la

oportunidad de salir adelante, creer en mí y en mis capacidades, siempre estaré eternamente agradecido por todo el apoyo que me brindó. A mis hermanos, Yamel, Heiseb y

Zaichel por estar siempre presentes, todo el amor y apoyo que me brindaron a lo largo de esta etapa de mi vida. Y por último a mis amigos Darney y Leiner que siempre me apoyaron, me

aconsejaron y me brindaron un poco de su conocimiento.

Agradecimientos

Agradezco a la Universidad de Pamplona por ser la sede de todo el conocimiento que he adquirido en estos años de formación profesional. Agradezco a Dios por brindarme su apoyo, sabiduría e inteligencia en todo momento de mi vida, a mis padres

Sebastian Hernandez y Ruby Arpushana por ser siempre mi apoyo en los momentos más duros y ser los principales promotores de mis sueños, Quiero agradecer al profesor Luis Muñoz Bedoya quien aceptó dirigir mi proyecto de grado y aclarar cualquier tipo de duda que me surgiera y agradecerle por su claridad y creer en mis capacidades.

El presente es de ellos; el futuro, para lo que realmente trabajé, es mío.

Nikola Tesla.

Resumen

La detección de cáncer de mama mediante inteligencia artificial es un gran avance en el apoyo médico para el diagnóstico temprano de éste, y ayudar a muchas mujeres que presentan sus síntomas. Debido a que es el cáncer más frecuente y de los que mayor tasa de mortalidad presenta, por eso, el objetivo principal de este proyecto es desarrollar un algoritmo basado en inteligencia artificial para la detección temprana de cáncer de mama a partir de imágenes histopatológicas y de mamografías de película escaneada mediante redes neuronales profundas (DNN) para brindar al médico un apoyo en el diagnóstico de forma eficiente del paciente, de esta forma, prevenir la metástasis a partes del cuerpo cercanas o alejadas de las mamas. Para clasificar el cáncer de mama se hace uso de dos tipos de imágenes: Imágenes de mamografías (1124 sacadas de Cancer Imaging Archive del conjunto de datos CBIS-DDSM), e imágenes histopatológicas (1204 sacadas de Kaggle del conjunto de datos Breast Histopathology). Se realizó un preprocesamiento sobre los datos primarios: cambio de campo de color de RGB a escala de grises, seguida de una etapa de binarización y de filtrado por eliminación de objetos según sus áreas (regionprops). Aplicando el método de Otsu se obtiene la máscara de los objetos de interés sobre cada imagen en RGB, seguida de una ecualización adaptativa por histograma para aumentar el contraste de esas áreas encontradas.

Sobre cada conjunto de imágenes se aplican técnicas de aumentación del conjunto de datos usando ImagingDataGenerator del paquete de Keras en el lenguaje de programación Python. Se desarrolló la creación de redes neuronales profundas como la Red Neuronal Residual y una ResNet50 para cada conjunto de imágenes, en el entrenamiento se aplicó la aumentación de datos por medio de iteraciones, el conjunto de datos de imágenes histopatológicas realizó 33 iteraciones a lo largo del entrenamiento, el conjunto de datos de imágenes de mamografías realizó 28 iteraciones en total. Se valida que tipo de imagen presenta mejores resultados para la clasificación del cáncer de mama. Posterior a esto, se realizó segmentación de imágenes para localizar los tumores benignos y malignos aplicada al conjunto de datos de imágenes de mamografías; finalmente, se desarrolló una API en el micro framework de flask, importando las librerías de Tensorflow y Keras, cargando el mejor modelo para la clasificación de cáncer de mama. Se utilizó la instancia EC2 de AWS para la creación de un entorno virtual para el alojamiento de la API, este servicio se realiza por medio de un protocolo SSH. Para el consumo de los servicios Backend al Frontend, AWS ofrece una dirección HTTPS para realizar peticiones entre usuario y servicio de la API. La página web es tipo estática programada en Html, Css y JavaScript como interfaz gráfica de usuario, donde se realiza predicciones del cáncer de mama.

Se logró obtener resultados por encima del 97.39% de eficacia con al ResNet50 para la detección del carcinoma ductal invasivo, obteniendo una validación en la red del 85% de acierto, no hay datos exactos sobre el margen de éxito y error de un especialista para la detección de cáncer, pero la gran diferencia que hay entre el especialista y el modelo creado es el tiempo de predicción del cáncer de mama, lo que significa horas de estudio y análisis para el especialista a la red le tomo segundos para procesar y dar un resultado con una gran precisión. Debido al muy bajo volumen de datos de imágenes de mamografía se logró alcanzar un resultado del 71.88% en la clasificación de tumores malignos y benignos, obteniendo predicciones en la validación erradas teniendo un 40% de acierto debido al subajuste de la red.

Palabras clave: Cáncer de mama, Mamografía, Inteligencia Artificial, Detección de cáncer, Red Neuronal Convolucional, Deep Learning, Machine Learning, Segmentación de imágenes, RESNET50, Red Neuronal Residual, Angular.

Abstract

The detection of breast cancer through artificial intelligence is a great advance in medical support for the early diagnosis of breast cancer, and to help many women who present with its symptoms. Because it is the most frequent cancer and the one with the highest mortality rate, the main objective of this project is to develop an algorithm based on artificial intelligence for the early detection of breast cancer from histopathological images and mammograms of scanned film using deep neural networks (DNN) to provide the doctor with support in the diagnosis of the patient efficiently, thus preventing metastasis to parts of the body near or far from the breasts. Two types of images are used to classify breast cancer: mammography images (1124 from Cancer Imaging Archive from the CBIS-DDSM dataset), and histopathology images (1204 from Kaggle from the Breast Histopathology dataset). Preprocessing was performed on the primary data: color field change from RGB to grayscale, followed by a binarization stage and filtering by object removal according to their areas (regionprops). Applying Otsu's method, we obtain the mask of the objects of interest on each image in RGB, followed by an adaptive equalization by histogram to increase the contrast of these found areas.

On each set of images, data set augmentation techniques are applied using ImagingDataGenerator from the Keras package in the Python programming language, the creation of deep neural networks such as the Residual Neural Network and a ResNet50 was developed for each set of images, in the training the data augmentation was applied by means of iterations, the histopathological image data set performed 33 iterations throughout the training, the mammography image data set performed 28 iterations in total. It is validated which type of image presents better results for the classification of breast cancer. After this, image segmentation was performed to locate benign and malignant tumors applied to the mammogram image dataset; finally, an Api was developed in the flask micro framework, importing the Tensorflow and Keras libraries, loading the best model for breast cancer classification. The EC2 instance of AWS was used to create a virtual environment for hosting the API, this service is performed via SSH protocol.

For the consumption of the Backend services to the Frontend, AWS provides an HTTPS address to make requests between the user and the API service. The web page is static type programmed in Html, Css and JavaScript as a graphical user interface, where breast cancer predictions are made. It was possible to obtain results above 97.39% efficiency with the ResNet50 for the detection of invasive ductal carcinoma, obtaining a validation in the network of 85% accuracy, there is no exact data on the margin of success and error of a specialist for the detection of cancer, but the big difference between the specialist and the model created is the time of prediction of breast cancer, which means hours of study and analysis for the specialist to the network took seconds to process and give a result with high accuracy. Due to the very low volume of mammography image data, a result of 71.88% was achieved in the classification of malignant and benign tumors, obtaining erroneous predictions in the validation with a 40% accuracy due to the under-adjustment of the network.

Keywords: Breast cancer, Mammography, Artificial Intelligence, Cancer detection, Convolutional Neural Network, Deep Learning, Machine Learning, Image segmentation, RESNET50, Residual Neural Network, Angular.

Índice general

Resumen	xi
Abstract	xiii
1 Introducción	1
1.1 Planteamiento de Problema	2
1.2 Justificación	3
1.3 Objetivos	4
1.3.1 Objetivo General	4
1.3.2 Objetivos específicos	4
1.4 Acotaciones	5
2 Marco Teórico	7
2.1 Cáncer de mama	7
2.1.1 ¿Cómo se propaga el cáncer de mama?	8
2.1.2 Síntomas del cáncer de mama	9
2.1.3 Pruebas y diagnóstico de cáncer de mama	9
2.1.4 Diferentes tipos de cáncer de mama.....	12
2.1.5 Base de datos de cáncer de mama	15
2.2 Procesamiento de imágenes.....	16
2.3 Inteligencia Artificial.....	16
2.3.1 Aprendizaje automático.....	17
2.3.2 Aprendizaje profundo.....	18
2.4 Redes Neuronales Convolucionales.....	18
2.4.1 Estructura de una red neuronal convolucional.....	20
2.4.2 Dropout	23
2.4.3 Función de activación.....	24
2.4.4 Redes neuronales Residuales.....	27
2.5 Segmentación de imágenes	30
2.5.1 UNet	32
2.6 Google Colaboratory	35
2.6.1 Python	35
2.6.2 Librerías de Python para la inteligencia artificial.....	36
2.7 Desarrollo web.....	36
2.8 API	37

2.9	Estado del Arte.....	37
3	Metodología	45
3.1	Preprocesamiento de Imágenes.....	47
3.1.1	Cambio de formato imagen	47
3.1.2	Redimensionamiento de imágenes	49
3.1.3	Filtrado de Imágenes	49
3.2	Aumentación de datos.....	51
3.3	Entrenamiento de Modelo de Red Neuronal Residual	55
3.4	ResNet50	61
3.5	U-net	61
3.6	Selección de métricas de clasificación	65
3.7	Selección del mejor modelo de red neuronal y predicción de imágenes con cáncer de mama.....	66
3.8	Página Web.....	67
3.8.1	Diseño de la página web	68
3.8.2	API.....	74
3.8.3	Consumo de la API.....	76
4	Resultados	81
4.1	Filtros aplicados y CLAHE	81
4.2	Datos Aumentados.....	82
4.3	Resultados De Entrenamiento De Las Redes Neuronales	83
4.3.1	Red Neuronal Residual y ResNet50 para imágenes de mamografía	85
4.3.2	Red Neuronal Residual y ResNet50 para imágenes histopatológicas	88
4.4	Predicción del cáncer de mama	91
4.5	Segmentación de imágenes.....	91
4.5.1	Segmentación de imágenes aplicado al CBIS-DDSM.....	93
4.5.2	Segmentación de imágenes aplicado a ultrasonido mamario.....	93
4.6	Página Web.....	93
5	Conclusiones	99
6	Bibliografía	101

Índice de figuras

2.1	Tejido mamario normal.	8
2.2	Ganglios linfáticos en relación con el seno.	9
2.3	Mamografía.....	10
2.4	Ecografía.....	11
2.5	MRI del seno.	12
2.6	Diagrama del carcinoma ductal invasivo.....	13
2.7	Carcinoma ductal invasivo in situ.....	14
2.8	Carcinoma lobulillar invasivo.	15
2.9	Esquema de neurona biológica y artificial.....	17
2.10	Evolución de la tasa de error en el desafío de Clasificación ILSVRC 2017.	19
2.11	Red con varias capas convolucionales.	20
2.12	Convolución.	21
2.13	Pooling.....	22
2.14	Pooling.....	22
2.15	Flaten.....	23
2.16	Dense.	25
2.17	Sigmoid.....	25
2.18	Tanh.....	26
2.19	ReLU.....	27
2.20	Error de entrenamiento (izquierda) y error de test(derecha).	28
2.21	Residual Learning: un bloque de construcción.....	29
2.22	Arquitectura de ResNet50.....	30
2.23	Ejemplo de segmentación de imágenes médicas.....	31
2.24	Arquitectura de UNet.	33
2.25	Arquitectura de una ResUNet.....	34
2.26	Google colab.....	35
2.27	Modelo de segmentación semántica basado en la atención.....	38
2.28	Estructura de la arquitectura de detección del cáncer de mama.	39
3.1	Metodología planteada.....	45
3.2	Conjunto de datos.....	46
3.3	Metodología aplicada a conjunto de imágenes de mamografía.....	46
3.4	Metodología aplicada a conjunto de imágenes histopatológicas.....	47
3.5	Visor de imagen médica MicroDicom.	48
3.6	Conversion de formato DICOM a PNG.....	49

3.7	Mamografía con ruido.....	50
3.8	Tratamiento de imágenes.	50
3.9	Carga de datos de Drive a Google Colab.	51
3.10	Distribución del conjunto de imágenes de mamografía.	52
3.11	Distribución del conjunto de imágenes histopatológicas.	53
3.12	Aumentación de imágenes histopatológicas.	54
3.13	Aumentación de imágenes de mamografía.	55
3.14	Modelo final de Red Neuronal Residual para la clasificación de imágenes con cáncer.	56
3.15	Bloque residual.	57
3.16	Bloques que conforman un bloque residual	58
3.17	Optimizador Adam.	60
3.18	Modelo U-net.	62
3.19	Bloque convolucional.	63
3.20	Bloque convolucional.	64
3.21	Bloque convolucional.	65
3.22	Matriz de confusión.....	66
3.23	Selección y predicción del mejor modelo de red neuronal.....	67
3.24	Desarrollo de Pagina Web.....	68
3.25	Diseño de página web.	69
3.26	Codigo html del Home page.	70
3.27	Codigo Angular del Home page.	71
3.28	Codigo html del Info page.....	72
3.29	Codigo Angular del Info page.	73
3.30	Codigo Angular del Info page.	74
3.31	API.....	75
3.32	API.....	76
3.33	Comunicación entre la API de flask por medio del protocolo SSH a los servicios de AWS	77
3.34	EC2 AWS.	78
3.35	Instacia EC2.....	78
3.36	MobaXterm.....	79
4.1	Filtros aplicados.....	81
4.2	Datos aumentados de las imágenes histopatológicas.	82
4.3	Datos aumentados de las imágenes de mamografía.....	83
4.4	Estructura de red residual compilada parte final.	84
4.5	Estructura de Resnet50 para el Breast Hisopathology Images.	85
4.6	Precisión de entrenamiento y validación de la red residual con las imágenes de mamografía.....	86
4.7	Perdidas de entrenamiento y validación de la red residual con las imágenes de mamografía.....	86

4.8	Precisión de entrenamiento y validación de la Resnet50 con las imágenes de mamografía.....	87
4.9	Perdidas de entrenamiento y validación de la Resnet50 con la base de datos del CBIS-DDSM.....	87
4.10	Precisión de entrenamiento y validación de la red residual con las imágenes histopatológicas.....	89
4.11	Perdidas de entrenamiento y validación de la red residual con las imágenes histopatológicas.....	89
4.12	Precisión de entrenamiento y validación de la Resnet50 con las imágenes histopatológicas.....	90
4.13	Perdidas de entrenamiento y validación de la Resnet50 con las imágenes histopatológicas.....	90
4.14	Estructura del modelo U-net para la segmentación de imágenes.	91
4.15	Ultrasonido y mascara respectiva.	92
4.16	Gráfica de precisión y perdida del modelo U-net con imágenes de ultrasonido mamario.	93
4.17	Página web Inicio.....	94
4.18	Menú Principal.....	95
4.19	Página web Inicio.....	96
4.20	Predicción del cáncer de mama.....	97
4.21	Contacto.	98

Índice de tablas

2.1	Estado del Arte	40
2.2	Estado del Arte	41
2.3	Estado del Arte	42
2.4	Estado del arte	43

1 Introducción

La inteligencia Artificial es la capacidad de las máquinas para usar algoritmos matemáticos capaz de interpretar datos, aprender de ellos y emplear esos conocimientos para realizar tareas en concreto, tomar decisiones tal y como lo haría un ser humano, A comparación de las personas las maquinas pueden manejar una infinidad de datos el cual el humano promedio no podría y reduce el error significativamente. En la inteligencia artificial se destacan el aprendizaje automático y el aprendizaje profundo, que utilizan redes neuronales artificiales e intentan imitar la manera que el cerebro procesa la información, la aplicación de la IA es innumerable. Las tecnologías basadas en IA han tenido gran impacto positivo en diferentes campos, como las finanzas, Domótica, Industria, Mercadotecnia, Reconocimiento facial, y en la Medicina. El avance y desarrollo de nuevas técnicas de la Inteligencia Artificial aplicadas a la medicina ha representado un avance significativo al apoyo médico. Puede brindar una reducción en los costos, menor tiempo y una mayor precisión de diagnóstico. Las aplicaciones de la Inteligencia Artificial en la medicina son numerosas, capaz de brindar una mejor atención médica en general. El análisis de imágenes médicas, diagnostico por imágenes médicas, tratamiento de enfermedades y predicción de enfermedades personalizado, en el caso de las imágenes médicas la inteligencia artificial es capaz de proporcionar una ayuda sustancial analizando rápidamente, tomografías computarizadas, radiográficas, mamografías y resonancias magnéticas, especialmente entornos de gran volumen y en hospitales con menos recursos humanos, estas aplicaciones pueden mejorarse exponencialmente a medida que la Inteligencia artificial evolucione con el tiempo. En este trabajo se presenta la implementación de la inteligencia artificial para detectar el cáncer de mama mediante redes neuronales profundas y técnicas de segmentación de imágenes y también el desarrollo de una página web creada mediante Angular, con el fin de observar la eficacia de los diferentes modelos de redes neuronales creadas para brindar un apoyo a futuras investigaciones y en un futuro un gran apoyo a los médicos. Se trabajo con dos bases de datos una de imágenes histopatológicas y otra de imágenes de mamografías de película escaneada, con el fin de entrenar los diferentes modelos, el cual nos permite extraer información a partir de los informes médicos en este caso las mamografías, proporcionando una ayuda al médico especialista a la hora de identificar el cáncer de mama en un menor tiempo, no se busca remplazar al especialista, solo brindarle un apoyo, trabajo en conjunto máquina-humano, porque estas carecen de momentos de cualidades humanas, tales como la empatía, razonamiento, compasión.

1.1 Planteamiento de Problema

El cáncer de mama es una gran problemática de salud pública ya que las mujeres constituyen el grupo con mayor vulnerabilidad y exposición frente a la enfermedad, frente a esta problemática se presentan los factores de riesgo, tales como ser una mujer de edad avanzada, antecedentes familiares y personales y malos hábitos como el alcohol. Estos riesgos aumentan la probabilidad de cáncer de mama y sin el rápido diagnóstico del cáncer este puede significar la muerte de la mujer. Datos del Global Cancer Observatory presentan un estudio de 185 países en el año 2020, que nos indica que el cáncer de mama fue el cáncer que presentó un mayor porcentaje de casos nuevos siendo este del 11.7% (2.261.419) así mismo el número de muertes a nivel global fueron de 684.996, representando el 6.9% [1]. Los estudios del Instituto Nacional de Cancerología -ESE Colombia indican que el cáncer más frecuente en mujeres es el cáncer de mama representando el 20% de los casos, debido a esto el cáncer de mama es una gran problemática a nivel mundial y nacional el cual se debe tomar medidas y estrategias para reducir el índice de mortalidad.

1.2 Justificación

Cuando se lleva a cabo la toma de una mamografía el proceso tarda unos 15 a 20 minutos, pero el tiempo que se tarda el especialista en revisar la mamografía y obtener los resultados puede variar, dicho tiempo puede resultar en una evolución del cáncer de mama y poner en riesgo la salud de las personas que presentan el cáncer, en este caso el propósito de este proyecto es desarrollar un algoritmo basado en inteligencia artificial para el diagnóstico de cáncer de mama y detectar el cáncer en posibles paciente que presentan los factores de riesgo en el menor tiempo posible, así mismo, apoyar al especialista para poder realizar un análisis más detallado de cada paciente que presente el cáncer porque no se busca remplazar al especialista si no brindar un apoyo significativo a sus diagnósticos, y sea un trabajo máquina-humano. Al disponer de un menor tiempo para el diagnóstico de cáncer se quiere aportar una reducción en la tasa de mortalidad que se presenta actualmente en Colombia, según datos del Global Cancer Observatory la tasa de mortalidad es del 8%, el cual en el año 2020 se presentó un total de 4411 muertes debido al cáncer de mama y a su vez incentivar a investigadores realizar estrategias para la detección de cáncer u otras enfermedades basado en la inteligencia artificial para su implementación en centros de salud.

1.3 Objetivos

1.3.1 Objetivo General

- Detectar el cáncer de mama a partir de imágenes histopatológicas y de mamografías mediante redes neuronales profundas y técnicas de segmentación.

1.3.2 Objetivos específicos

- Acondicionar con técnicas de preprocesamiento las bases de datos de mamografías e histopatologías para la identificación y clasificación del cáncer de mama.
- Implementar redes neuronales convolucionales modernas para la clasificación de tumores malignos y benignos.
- Validar los modelos implementados para la detección de cáncer de mama usando imágenes aportadas por las bases de datos en tiempo real.
- Desarrollar interfaz gráfica de usuario como herramienta de apoyo para el especialista.

1.4 Acotaciones

Para el entrenamiento y evaluación del proyecto se usará el lenguaje de programación de alto nivel como Python ya que este cuenta con librerías y herramientas de inteligencia artificial. Se usaran diversas bases de datos para el entrenamiento de las redes neuronales para validar la efectividad de estas para la clasificación del cáncer de mama, se hará uso de la base de datos libre del Cancer Imaging Archive, la base de datos usada es el CBIS-DDSM que cuenta con más de 1000 estudios de mamografía de película escaneada, conteniendo casos malignos y benignos con información patológica verificada y otra base de datos a utilizar es el Breast Histopathology Images que cuenta con imágenes del carcinoma ductal invasivo (CDI) es el subtipo más común de todos los cánceres de mama. Para este tipo de clasificación se requiere equipos de cómputo bastante elevados, por el cual se opta por trabajar por medio de gpu gratuitas las cuales ofrece Google Collab para el entrenamiento de redes neuronales profundas.

2 Marco Teórico

2.1 Cáncer de mama

El cáncer de mama se origina cuando las células mamarias se multiplican sin control. Las células cancerosas del seno normalmente forman un tumor que se puede observar en una radiografía, el cáncer de seno se presenta más en mujeres, pero los hombres también pueden presentarlo y ocurre con mayor frecuencia entre los 60 y 70 años, datos del American Cancer Society [46] y el BreastCancer.org [47] aproximadamente 1 de cada 1000 casos de cáncer de mama en los Estados Unidos se diagnostica en un hombre.

Los cánceres de seno pueden originarse en diferentes partes del seno. En la figura 2.1 Se puede observar a fondo el Tejido mamario normal

- Cánceres ductales, la mayoría de los cánceres de mama comienza en los conductos que llevan la leche.
 - Cánceres lobulillares, Se origina en las glándulas que producen leche.
 - Cánceres en el Tejido conectivo, se origina en la parte donde se rodea y sostiene todas las partes de la mama.[2]
-




Figura 2.1: Tejido mamario normal.

Fuente: American Cancer Society, septiembre 18, 2019

Hay muchos tipos diferentes de cáncer de mama, los más comunes son el carcinoma ductal in situ y carcinoma invasivo, estos tipos de cáncer se pueden propagar cuando las células cancerosas alcanzan a la red de vasos linfáticos y estas se pueden propagar a otras partes del cuerpo conocido como metástasis.[2]

2.1.1 ¿Cómo se propaga el cáncer de mama?

El cáncer de mama puede propagarse cuando las células cancerosas penetran en la sangre o el sistema linfático, lo que se denomina metástasis, y se extienden a otras partes del cuerpo. En la figura 2.2 se puede apreciar los ganglios linfáticos en relación con el seno.

- Los ganglios linfáticos localizados debajo del brazo (ganglios axilares)
- Los ganglios linfáticos que rodean la clavícula (ganglios linfáticos supraclaviculares [encima de la clavícula] e infraclaviculares [debajo de la clavícula])
- Los ganglios linfáticos que se encuentran en el interior del tórax y cerca del esternón (ganglios linfáticos mamarios internos) [1]




Figura 2.2: Ganglios linfáticos en relación con el seno.

Fuente: American Cancer Society, septiembre 18, 2019

2.1.2 Síntomas del cáncer de mama

El cáncer de mama presenta varios síntomas, esto pueden ser signos de advertencia para ir a un especialista, estos son algunos de los síntomas más comunes:

- Un bulto nuevo en la mama o la axila.
- Aumento del grosor o hinchazón de una parte de la mama.
- Irritación o hundimientos en la piel de la mama.
- Dolor en el seno o en el pezón.
- Retracción (contracción) de los pezones
- Piel del pezón o seno roja, seca, descamada o gruesa
- Secreción del pezón que no sea leche materna
- Ganglios linfáticos hinchados [2]

2.1.3 Pruebas y diagnóstico de cáncer de mama

Mamografías

Las mamografías son imágenes de las mamas tomados por medio de rayos x (radiografía), este proceso se muestra en la figura 2.3, está en bajas dosis para ayudar a encontrar el cáncer de mama, con el fin de encontrar el cáncer en sus etapas iniciales. Las mamografías se realizan colocando los senos en una placa de plástico, presionando firmemente para mantener los senos inmóviles para que se pueda realizar la radiografía [2]




Figura 2.3: Mamografía.

Fuente: Instituto nacional del cáncer

Ecografía del seno

La ecografía mamaria utiliza ondas sonoras para crear una imagen informatizada del interior de la mama. Esta prueba puede mostrar algunos cambios en la mama, como quistes llenos de líquido, que son más difíciles de identificar con una mamografía.[2]

Este proceso se realiza aplicando un gel en el seno y usando un transductor para emitir ondas sonoras y detectar los ecos en los tejidos mamarios, como en la figura 2.4 donde se realiza el proceso de ecografía.




Figura 2.4: Ecografía.
Fuente: Web Healthline

Resonancia magnética del seno

La resonancia magnética es utilizada en mujeres previamente diagnosticada con cáncer de mama, la MRI es usado para determinar la extensión del cáncer de mama para medir el tamaño del cáncer, en la figura 2.5 se puede visualizar el proceso de una MRI.




Figura 2.5: MRI del seno.
Fuente: American Cancer Society, septiembre 18, 2019

2.1.4 Diferentes tipos de cáncer de mama

Existen diferentes tipos de cáncer de mama. Algunos son raros. A continuación, se indican los nombres médicos de los tipos más comunes de cáncer de mama.

Carcinoma ductal invasivo (IDC)

En la figura 2.6 muestra el diagrama de carcinoma ductal invasivo, el carcinoma ductal invasivo (IDC) es el tipo de cáncer de mama más frecuente en el mundo. Representa alrededor del 75% de todos los cánceres de mama, lo que significa que 8 de cada 10 cánceres de mama son carcinomas ductales invasivos. El IDC comienza en las células que recubren el conducto lácteo de la mama. A partir de aquí, el cáncer penetra en la pared del conducto y crece en el tejido mamario circundante. En esta fase, puede tener la capacidad de propagarse (metástasis) a otras partes del cuerpo a través del sistema linfático y el torrente sanguíneo [4].




Figura 2.6: Diagrama del carcinoma ductal invasivo.
Fuente: BreastCancer.org, 18 de noviembre de 2022

En la figura se puede visualizar el diagrama de carcinoma ductal invasivo, se presenta el perfil mamario y su respectiva ampliación

Perfil mamario

- A. Conductos
- B. Lóbulos
- C. Sección dilatada del conducto para retener la leche.
- D. Pezón
- E. Grasa
- F. Músculo pectoral mayor
- G. red torácica

Ampliación

- A. Célula del conducto normal
 - B. Células cancerosas ductales que rompen la membrana basal
 - C. Membrana basal
-

Carcinoma ductal in situ

El carcinoma ductal in situ (CDIS) es un cáncer de mama en estadio muy inicial, en la figura se puede apreciar el CDIS, lo que significa que las células cancerosas sólo se encuentran dentro de los conductos galactóforos (los conductos galactóforos son tubos finos que llevan la leche al pezón). En la figura 2.7 se puede ver los conductos galactóforos con CDIS, las células cancerosas no se han extendido a través de las paredes de los conductos a otros tejidos circundantes.[4]




Figura 2.7: Carcinoma ductal invasivo in situ.

Fuente:National Cancer Institute © 2012 Terese Winslow LLC

Carcinoma lobulillar in situ

El carcinoma lobulillar in situ (LCIS) comienza en las glándulas productoras de leche (denominadas lobulillos), pero no se extiende más allá del revestimiento de estas glándulas. No es un cáncer, pero las pacientes con LCIS tienen más probabilidades de desarrollar cáncer de mama. [4]

Carcinoma lobulillar invasivo

Este cáncer de mama comienza en las glándulas mamarias, que se denominan lobulillos. Puede extenderse a otras partes del cuerpo en la figura 2.8 se aprecia el ILC.[4]




Figura 2.8: Carcinoma lobulillar invasivo.

Fuente:National Cancer Institute © 2012 Terese Winslow LLC

2.1.5 Base de datos de cáncer de mama

La primera base de datos utilizada en este trabajo de grado es sacada del CANCER IMAGING ARCHIVE, se hace uso de los datos del CBIS-DDSM (Base de Datos Digital para mamografías de detección), esta base de datos cuenta con más de 1200 estudios de mamografías de película escaneada, la base de datos contiene casos benignos y malignos. Las imágenes de la base de datos fueron comprimidas y convertidas a formato DICOM (Digital Imaging and communications in medicine), este es un formato estándar internacional para imágenes médicas y también incluyen la segmentación actualizada del ROI el cual es la región de interés este se puede representar como máscara binaria. En la máscara, los píxeles que pertenecen a la ROI tienen el valor 1, y los que se sitúan fuera tienen el valor 0. Y el diagnóstico patológico para los datos de entrenamiento. [3]

La segunda base de datos utilizado para el entrenamiento de las redes neuronales es el Breast Histopathology Images, El carcinoma ductal invasivo (IDC) es el subtipo más frecuente de todos los cánceres de mama. Los patólogos suelen centrarse en las zonas que contienen IDC a la hora de determinar la agresividad de toda la muestra. Por lo tanto, uno de los pasos comunes del preprocesamiento para la clasificación automática de agresiones es delimitar con precisión las áreas IDC en toda la muestra. El conjunto de datos original constaba de 162 imágenes de muestras enteras de cáncer de mama (BCa) escaneadas con un aumento de 40x. De ellas se extrajeron 277.524 parches 50 x 50 (198.738 IDC negativas y 78.786 IDC positivas). [46]

2.2 Procesamiento de imágenes

El tratamiento digital de imágenes (PDI) es un conjunto de técnicas y procesos para detectar o resaltar información en una imagen utilizando un ordenador como herramienta principal. Actualmente, la PDI es un área de investigación muy específica en el campo de la informática y está estrechamente relacionada con el procesamiento digital de señales. Esta relación se deriva del hecho de que la DSP es esencialmente una forma muy específica de procesamiento digital de señales en dos o tres dimensiones [5].

2.3 Inteligencia Artificial

La inteligencia artificial IA hace referencia a sistemas o maquinas que imitan la inteligencia humana, para realizar tareas con un propósito en específico y que puedan mejorar iterativamente con los datos suministrados o que recopilan.[6]

El campo de la inteligencia es tan amplio que se usa la capacidad de la IA de aprender datos y utilizarlo para la toma de decisiones y predicciones tal como lo haría un ser humano, pero con menos margen de error, el cual nos beneficia para realizar proyectos como la detección de cáncer de mama. La IA será capaz de ofrecernos un mayor desempeño en el tiempo de detección de una enfermedad, clasificar la enfermedad y otros factores que benefician en el campo médico.

Las redes neuronales se basan en el modelo abstracto y matemático de una neurona artificial que realizaron McCulloch and Pitts en 1943.




Figura 2.9: Esquema de neurona biológica y artificial.

Fuente: Towards Data Science, 2021

En la Figura 2.9 la neurona artificial recibe un conjunto de entrada de $X_1, X_2, \dots, X_n$ esta devuelve una salida Y , una neuronal biológica también recibe varias entradas a través de las dendritas. La neurona artificial recibe un vector de pesos $W_1, W_2, \dots, W_n$ que es equivalente a las conexiones sinápticas de una neurona real, b es el umbral de activación.

Una neurona artificial simple toma las entradas $X_1, X_2, \dots, X_n$ y las multiplica con los pesos $W_1, W_2, \dots, W_n$ para luego calcular la función lineal Z , para luego aplicar una función de activación f esta funciones de activación pueden ser ReLU, sigmoid, binary step para luego obtener una única salida.[7]

2.3.1 Aprendizaje automático

El Machine Learning es uno de los enfoques principales de la IA, el cual es la práctica de usar algoritmos para aprender de los datos de entrada proporcionados, sin necesidad de estar programados, es decir su arquitectura aprende automáticamente debido a las repeticiones (experiencia) para lograr la tarea designada.

Hay ventajas que presenta el aprendizaje automático, el cual es la reducción de tiempo para identificar patrones complejos en los datos de entrada y sustituir el trabajo laborioso, ventajas que favorecen a la detección de cáncer.

El Machine Learning tiene 3 categorías de algoritmos según la naturaleza de los datos de entrenamiento, que son:

- Aprendizaje Supervisado.
- Aprendizaje no supervisado.
- Aprendizaje de refuerzo.

Aprendizaje supervisado

En el aprendizaje supervisado está basada en tareas, usan datos previamente etiquetados y organizados para luego categorizar la nueva información, esta requiere de intervención humana.

Aprendizaje no supervisado

En el aprendizaje no supervisado está basado en datos, no usan datos etiquetados u organizados, el cual el algoritmo debe extraer todo tipo de información para encontrar la manera de clasificar los datos ellos mismos.

Aprendizaje por refuerzo

El aprendizaje por refuerzo aprende a reaccionar a su entorno, es decir aprenden de la experiencia, cada vez ir entrenando el algoritmo con nuevos datos para que este refuerce lo aprendido y pueda clasificar mejor.[8]

2.3.2 Aprendizaje profundo

El Deep Learning se utiliza para resolver tareas muy complejas y necesitan una gran cantidad de datos para poder realizarlas, es una subcategoría del aprendizaje automático, este usa las redes neuronales que se organizan en capas para reconocer patrones complejos, su nivel de procesamiento es alto, sirve para el reconocimiento de voz, visión artificial y procesamiento del lenguaje natural.[9]

2.4 Redes Neuronales Convolucionales

Las redes neuronales convolucionales es un tipo de red neuronal, el cual cuenta con múltiples capas, son muy efectivas para la visión artificial, el cual ha tenido mucho éxito debido a su sobresaliente desempeño en aplicaciones relacionadas a imágenes. Gracias a este tipo de red neuronal se ha podido crear sistemas de clasificación de imágenes con un porcentaje de error considerablemente mejor frente otros tipos de neuronas (como son la adaline, perceptron multicapa, etc), gracias a esto en la parte de salud ha aportado una mayor precisión a crear modelos de redes neuronales convolucionales para la detección de enfermedades.




Figura 2.10: Evolución de la tasa de error en el desafío de Clasificación ILSVRC 2017.

Fuente: PhD. Sik-Ho Tsang, 2019

En la Figura 2.10 se aprecia la evolución de la tasa de error de las redes neuronales, esta evolución se ha logrado debido al desafío de ImageNet Large Scale Visual Recognition (ILSVRC), donde se han presentado muchos trabajos con el fin de presentar el mejor modelo para la clasificación de imágenes y detección de objetos sobre el conjunto de imágenes de ImageNet. [10]

El desafío de ILSVRC se realizó en el año 2009 pero no fue hasta el año 2012 que se empezaron implementar las redes neuronales convolucionales que la tasa de error empezó a mejorar creando modelos más y más efectivos como en el caso de la SENet[11], con una tasa de error del 0.023%.

La estructura de una red neuronal convolucional es tener datos de entrada, los datos de entrada son imágenes, el cual esas imágenes son llevadas a capas convolucionales para entrenar una gran cantidad de filtros el cual se va a especializar en extraer diferentes características de la imagen.

Las redes neuronales convolucionales son capaces de aprender en los diferentes niveles de abstracción: en la primera capa se diferencian formas simples, colores o bordes; en la siguiente se pueden distinguir combinaciones de bordes y colores; mientras que la última capa se fija en la forma con el fin de conseguir averiguar qué es exactamente.[12]

Actualmente existen redes neuronales profundas modernas ya creadas que han demostrado tener una capacidad de aprendizaje muy alta en la clasificación de imágenes, estas redes neuronales son las siguientes:

- AlexNet.
- VGGNet.
- GoogleNet.

- ResNet
- Sen-Net
- entre otros trabajos.

En este trabajo se utilizó el siguiente modelo de red neuronal profunda, para comprobar la efectividad del modelo para la detección de cáncer de mama

- ResNet.

2.4.1 Estructura de una red neuronal convolucional

En la figura 2.11 se puede ver la arquitectura de una red neuronal convolucional de varias capas.




Figura 2.11: Red con varias capas convolucionales.

Fuente: Redes neuronales convolucionales, Mathworks

Las CNN está compuesta por una capa de entrada, salida y capas intermedias ocultas, las capas más utilizadas en un CNN son la capa de convolucion, Activacion y de Pooling[13]

Capa de convolución

La capa de convolución es la capa donde se realiza operaciones de suma y producto punto de cada pixel tomado de la imagen e indicar el tamaño del filtro denominado

kernel que genera un mapa de característica como se muestra en la figura, con el fin de reducir número de parámetros a entrenar. [14]




Figura 2.12: Convolución.

Fuente: Diego Calvo, 2017

Pooling

El pooling es la operación de reducción de parámetros, este reduce las dimensiones sin tocar la profundidad con el fin de reducir el número de parámetros el cual ayudara mucho al momento de entrenar una red neuronal y ayuda al sobre ajuste del modelo. La forma común de reducir parámetros mediante la operación de pooling es mediante la extracción de características promedio o el máximo de una agrupación (MaxPooling), al reducir las características pierde un poco de precisión.[14]




Figura 2.13: Pooling.
Fuente: Diego Calvo, 2017

Flatten

Esta capa convierte la imagen de tres dimensiones a una sola, como se muestra en la figura 2.14.




Figura 2.14: Flatten.
Fuente: [diegokoz.github.io](https://github.com/diegokoz)

Dense

La capa densa es una fully connected layer que recibe como input el producto aplastado de las capas previas, esta capa densa se puede observar




Figura 2.15: Dense.

Fuente: [diegokoz.github.io](https://github.com/diegokoz)

2.4.2 Dropout

El dropout es un método que desactiva aleatoriamente una serie de neuronas de una red neuronal. En cada iteración de la red neuronal, el dropout desactiva varias neuronas y las neuronas deficientes no se tienen en cuenta para la propagación hacia delante y hacia atrás, lo que obliga a las neuronas circundantes a no depender de las neuronas deficientes. Esto reduce el sobreajuste, porque las neuronas vecinas tienden a aprender patrones relacionados, y estas relaciones pueden formar un patrón muy específico con los datos de entrenamiento. Cuando se deteriora, esta dependencia entre neuronas de toda la red neuronal se reduce, de modo que las neuronas pueden trabajar mejor por su cuenta y no dependen tanto de las relaciones con las neuronas vecinas.

Bath normalization

La normalización por lotes es un método que normaliza cada lote de datos (`batch_size`); como vimos en el tutorial de keras, es necesario normalizar los datos para evitar distancias muy diferentes, como en la imagen en color, que puede tener valores entre 0 y 255. Al normalizar los datos, las distancias de los datos pasan de 0 a 1, lo que permite que la red neuronal funcione mejor y tenga menos problemas, pero cuando normalizamos los datos, sólo se beneficia la capa de entrada. Cuando los datos pasan por otras

capas ocultas, esta normalización se pierde y si tenemos una red neuronal con muchas capas, podemos tener problemas de entrenamiento. El método de normalización por lotes normaliza los datos antes de que pasen por la función de activación en cada capa de la red neuronal, de modo que siempre tengamos datos normalizados.


Este método también resuelve un problema llamado covariate shift, si queremos entrenar una red neuronal necesitamos una gran cantidad de datos, en la red neuronal que creamos teníamos imágenes de patrones tesla, cuando se está entrenando la red neuronal recuerda que dividimos los datos entrenados en lotes más pequeños (tamaño del lote), si las imágenes de los coches tienen diferentes distribuciones, por ejemplo un cierto número de imágenes son tesla rojos y otro número son tesla azules, es necesario que cada lote contenga imágenes de ambas distribuciones, si el lote contiene sólo imágenes de un color tesla, el aprendizaje será más lento y tendremos que elegir con más cuidado los hiperparámetros como la tasa de aprendizaje, este problema se puede solucionar si mezclamos aleatoriamente los datos, pero esto sólo ayudará a la capa de entrada, en las capas ocultas la distribución de cada neurona cambia durante la fase de aprendizaje, lo que buscamos es tener una distribución fija en cada neurona.

2.4.3 Función de activación

La capa de activación se emplea para mapear la no linealidad avanzada que entre la entrada y la salida. La función principal de esta capa es convertir el grado de señal asociado de un nodo de la red neuronal en una señal, que se utiliza en la siguiente capa de la pila. Sin la utilización de la función de activación, la señal sería simplemente una función de regresión rectilínea directa. Es un método sencillo de desentrañar; sin embargo, está restringido con potencia y complejidad. Además, si la función de activación no se aplica en la red neuronal, la red no sería capaz de aprender y modelar conocimientos difíciles alternativos como imagen vídeo, audio y habla, etc. Los distintos tipos de funciones de activación utilizados son Sigmoid, Tanh, ReLu, Leaky ReLu y Maxout.


Sigmoid

La función de activación sigmoidea se utiliza para la clasificación binaria que oscila entre los valores (0-1) y su gráfico se muestra en la Figura 2. El fallo de la activación sigmoidea se debe a cuatro problemas principales: 1. La función sigmoide conduce a un inconveniente de gradiente decreciente. 2. La optimización es más difícil porque la salida no es zerocéntrica, por lo que hace que las actualizaciones del gradiente se alejen demasiado en 3. En cierto punto del tiempo, la función sigmoidea satura y mata los gradientes. 4. La función sigmoidea tiene una convergencia lenta.

**Figura 2.16:** Sigmoid.**Fuente:** Deepai.org

Tanh

La función hiperbólica tangente es una versión desplazada de la sigmoidea. La función tanh, que se muestra en la Figura 2.17, no está centrada en cero porque la gama está entre -1 y 1 por lo tanto hace la optimización mucho fácil. A pesar de que hay bastante mejora en comparación con sigmoidea sigue sufriendo problemas de gradiente decreciente.

**Figura 2.17:** Tanh.**Fuente:** Deepai.org

Softmax

el softmax se utiliza para la función multiclase donde el número de clase es mayor. El softmax no es más que una simple función de probabilidad donde las salidas se predicen como una clase particular con un valor predicho. en la figura 2.18 se puede apreciar su fórmula de salida.


$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$$

Figura 2.18: Softmax.

Fuente: Deepai.org

ReLU

La ReLU también denominado función de activación, en la figura 2.19 se muestra la función y ecuación. este nos permitirá realizar un entrenamiento más eficaz y rápido asignando valores negativos a cero y valores positivos a uno, esto con el fin de solo activarse cuando las características sean una y pasar a la siguiente capa.[13]

**Figura 2.19:** ReLU.**Fuente:** Deepai.org/machine

2.4.4 Redes neuronales Residuales

Las redes neuronales Residuales (ResNet) es una red muy popular desarrollada en el 2015, ganó el concurso de ImageNet ILSVRC, este modelo se ha convertido en un referente de las redes neuronales convolucionales y es uno de los modelos más utilizados para trabajos de clasificación debido a que su número de capas es muy profundo, más de 100 capas.[15]

Existe un problema en las redes neuronales cuando estas presentan una profundidad considerable, cada vez que se agrega más capas a la red esta va teniendo problemas para su entrenamiento y dificulta más el trabajo debido al desvanecimiento del gradiente.




Figura 2.20: Error de entrenamiento (izquierda) y error de test(derecha).

Fuente: Kaiming He, *Deep Residual Learning for Image Recognition*, 2015

En la Figura 2.20 se explica mejor el problema que presentan las redes neuronales segun Kaiming He, cada vez que las redes se hacen más profundas este pierde mayor precisión en el entrenamiento, se compara dos redes una de 20 capas y otra de 56 capas, se aprecia que la red más profunda tiene un mayor error de entrenamiento y por lo tanto un mayor error de prueba frente a la otra red más sencilla.

La propuesta que hacen en el artículo de Deep Residual Learning for Image Recognition [16] es utilizar el aprendizaje residual, En lugar de esperar que cada una de las capas apiladas se ajuste directamente a un mapeo subyacente deseado, se deja explícitamente que estas capas se ajusten a un mapeo residual. Es decir, hacen una especie de atajo para lograr la función de identidad (x) como se muestra en la Figura 2.9, suman el resultado de la weight layer con la función de identidad x mediante una función de activación relu y este resultado se guarda como salida para las siguientes capas que se van a ir agregando, esto con tal de hacer el modelo más eficiente y evitar el problema de desvanecimiento del gradiente.

$$H(x) = F(x) + x \quad (2.1)$$

La ecuación 2.2 explica la suma de $F(x)$ que es la suma de las weight layer que es el flujo original de una red neuronal y la función identidad x , todo esto es tener el mapeo residual.




Figura 2.21: Residual Learning: un bloque de construcción.

Fuente: Kaiming He, Deep Residual Learning for Image Recognition, 2015

Hay diferentes arquitecturas en las ResNet una de las más populares son las ResNet50, la arquitectura de esta red se puede ver en la Figura 2.10, esta arquitectura nos va a ayudar a comprender el funcionamiento de las redes residuales, estas presentan bloques residual de identidad y bloques residual de convolución, el bloque residual de identidad es nombrado de esa forma porque los datos (los datos de entrada son imágenes) que son "puenteados" en este caso ese puente es la función de identidad x no son modificados, esto es debido porque el tensor que resulta de las etapas convolucionales denominado $F(x)$ es de las mismas dimensiones que los datos originales, por lo que no es necesario ajustar las dimensiones de cada salida para sumarlos. Y en el bloque residual convolucional las dimensiones de la función de identidad x y etapas convolucionales $F(x)$ son distintas, debido al incremento de número de canales o por las dimensiones espaciales del tensor, es necesario aplicar una operación a la función de identidad x para hacer que las dimensiones coincidan esto se puede apreciar en la Figura 2.10 del bloque residual convolucional.[17]




Figura 2.22: Arquitectura de ResNet50.

Fuente: Qingge Ji, *Optimized Deep Convolutional Neural Networks*, 2019

2.5 Segmentación de imágenes


La segmentación de imágenes subdivide una imagen en sus partes constituyentes u objetos, con el fin de separar las regiones de interés del resto de la imagen. En el proceso de detectar las partes de interés en una imagen es mediante la identificación de bordes de la imagen, segmenta las regiones, líneas o curvas, etc. [18]

La segmentación automática es una de las tareas más complicadas del procesamiento de imágenes, esta etapa determina el éxito o fallo del análisis de la imagen, muchos trabajos de investigación se centran en este problema.

Existen diversos métodos de segmentación de imágenes y es posible que se implementan, los métodos de segmentación más comunes y usados son:

- Establecimiento de Umbrales.
- Detección de bordes.
- Análisis de texturas.
- Agrupamiento.

- Modelos deformables.



(a) Mamografía.



(b) Mascara de la Mamografía.

Figura 2.23: Ejemplo de segmentación de imágenes médicas

Fuente: Cancer Imaging Archive CBIS-DDSM

Detección de bordes

Los métodos de extracción de bordes de una imagen, se basan en la diferencia que experimenta una característica en dos regiones adyacentes y que indican la existencia de un borde. A la vez los bordes pueden clasificarse por su anchura, ángulo de su pendiente de variación, y las coordenadas de su punto medio.

Umbralizacion

La umbralización es uno de los métodos más importantes de la segmentación de imágenes. Se define el umbral como una función que convierte una imagen con diferentes tonalidades en una imagen en blanco y negro.

Análisis de Textura

Si el objeto de estudio no presenta una intensidad uniforme, sino que muestra cierta trama, este objeto puede ser distinguible a esto se le denomina textura visual.[19]

Como las propiedades se pueden encontrar dentro de un tipo de textura que son muy variadas, se debe primero obtener un cierto promedio local. luego se calculan los valores de promedios de propiedades locales y se toman sus diferencias de promedio con el cual se calcula el gradiente de textura en cada píxel y con esto detectar los bordes entre regiones de diferentes texturas.[19]

Agrupamiento

Este método es esencialmente una técnica de reconocimiento de patrones que buscan particionar un espacio característico.

2.5.1 UNet

La segmentación semántica ha tenido grandes avances en los últimos años en el campo de las imágenes biomédicas donde se han desarrollado diferentes técnicas especializadas para mejorar el rendimiento de la segmentación final, en el área de la segmentación de imágenes biomédicas se tiene que hablar de la arquitectura U-Net (Olaf Ronneberger, Philipp Fischer, and Thomas Brox, 2015) que introdujo el paradigma codificador-decodificador, para aumentar gradualmente el tamaño de las características de menor tamaño al tamaño de la imagen original, donde este realiza la tarea de localizar objetos en el caso de tumores, la masa maligna. [20]

La segmentación de imágenes es el método para dividir la imagen en varios segmentos con cada segmento que tiene una entidad diferente. Las redes neuronales convolucionales tienen éxito para imágenes más simples, pero no han dado buenos resultados para imágenes complejas. Aquí es donde entran en juego otros algoritmos como U-Net y Res-Net.[21]

La arquitectura U-Net fue creada en el año 2015 por Olaf Ronnerberger, Philipp Fischer y Thomas Brox en la figura se puede visualizar el modelo completo de la red. La U-Net presenta tres partes:

- Codificador

 - Cuello de botella

 - Decodificador
-




Figura 2.24: Arquitectura de UNet.

Fuente: Olaf Ronneberger, Philipp Fischer, and Thomas Brox, U-Net, 2015

Codificador

La ruta de encoder o ruta de contracción consta de varios bloques de contracción, cada bloque de contracción recibe una entrada que pasa a través de res-blocks seguida de agrupación máxima de 2x2. Los mapas de características después de cada dos bloques se duplican, lo cual esto ayudara al modelo aprender características más complejas de manera efectiva.[21]

Cuello de botella

El bloque de cuello de botella sirve para realizar la conexión entre la ruta de contracción (Codificador) y la ruta de expansión (Decodificador).

El bloque de cuello de botella toma la entrada y luego pasa a través de un bloque de res seguido de un muestreo de capas de convolución 2x2[21]

Decodificador

La ventaja de esta arquitectura radica en la ruta de expansión (Decodificador), cada bloque toma la entrada muestreada de la capa anterior y se concatena con las características de salida correspondientes de los bloques res en la ruta de contracción,

esto luego se pasa nuevamente por el bloque res seguido por capas de convolución de muestreo ascendente 2x2.

Esto ayuda a garantizar que las características aprendidas durante la contracción se utilicen al reconstruir la imagen.

En la última capa de la ruta de expansión, la salida del bloque res pasa a través de la capa de convolución 1x1 para producir la salida deseada con el mismo tamaño que la entrada.[21]




Figura 2.25: Arquitectura de una ResUNet.

Fuente: Foivos I. Diakogiannisa, François Waldnerb, Peter Caccettaa, Chen Wu, ResUNet-a, 2020

2.6 Google Colaboratory

Colaboratory, o Colab” para abreviar, es un producto de Google Research. Google colab permite al usuario escribir y ejecutar código python en linea en cualquier navegador. Las ventajas de esta plataforma es que no se necesita de ninguna configuración en la maquina pues solo es necesario el acceso a internet, permite el acceso de hardware especializado como GPUs y TPUs tanto el acceso gratuito y de pago, Google colab está pensado para estudiantes, investigadores y científico de datos, para tareas de aprendizaje automático, análisis de datos.

Google colab presenta ventajas por tener los datos manejados en la nube (Google Drive) y compartir los cuadernos con otros usuarios y revisar cuadernos de Jupyter Notebook, sin descargar e instalar nada.[22]



Figura 2.26: Google colab.

Fuente: Google Colaboratory

2.6.1 Python

Python es un lenguaje de programación de alto nivel, sencillo de leer y escribir.

Python es un lenguaje de programación multiplataforma y de código abierto que puede utilizarse tanto para desarrollo web, creación de software y procesamiento de datos, entre muchos otros propósitos, gracias a su sencillez y a sus amplias posibilidades, sobre todo en los últimos años, ya que facilita trabajar con inteligencia artificial, big data, machine learning y data science, entre muchos otros campos en auge. Fue lanzado por primera vez en 1991 por Guido van Rossum y sigue siendo desarrollado hoy en día por la Python Software Foundation[23]

2.6.2 Librerías de Python para la inteligencia artificial

Tensorflow

Crea y entrena modelos innovadores sin sacrificar la velocidad ni el rendimiento. TensorFlow ofrece flexibilidad y control con funciones como Keras Functional API y Model Subclass API para crear topologías complejas. Utilice Instant Start para facilitar la creación rápida de prototipos y la depuración. TensorFlow también soporta un ecosistema de potentes plugins y librerías de modelos para experimentación, incluyendo Ragged Tensors, TensorFlow Probability, Tensor2Tensor y BERT [24].

Keras

Keras es una biblioteca de código abierto para redes neuronales escrita en Python. Puede ejecutarse en TensorFlow, Microsoft Cognitive Toolkit o Theano. Está diseñado específicamente para permitir la experimentación a corto o largo plazo con redes de Deep Learning. Proporciona una API coherente y sencilla, minimiza el número de acciones de usuario necesarias para los casos de uso comunes y proporciona mensajes de error claros y utilizables. También incluye amplia documentación y guías de desarrollo. Construido sobre la plataforma TensorFlow 2.0, Keras es un robusto framework industrial que puede escalar a grandes clusters de GPUs o a un pod completo de TPUs. Los modelos de Keras pueden exportarse a JavaScript y ejecutarse directamente en el navegador, en TF Lite y ejecutarse en iOS, Android y dispositivos integrados. Los modelos Keras también se pueden servir fácilmente a través de una API web [25].

2.7 Desarrollo web

Por desarrollo web entendemos la programación necesaria para la construcción de aplicaciones o sitios web, en la cual el mayor trabajo es poder mantenerlas impecables, en correcto funcionamiento y con buena seguridad. [26].

Aunque el desarrollo web sea un ámbito específico del desarrollo de software en general, el gran ecosistema de las tecnologías, lenguajes de programación y herramientas disponibles para la creación web es exageradamente grande. Para poder clasificar o dividir las áreas del desarrollo web se han dividido un par de términos:

Frontend

La parte encargada del diseño, composición y actividad de que una idea sea convertida en realidad, es el desarrollo web en el ámbito del cliente, es decir, en el navegador web. Las tecnologías principalmente usadas son HTML, CSS y el lenguaje de programación JavaScript.

Backend

Es la parte no visible, es decir, donde están todos los datos almacenados, es el desarrollo web en el ámbito del servidor, donde las tecnologías y lenguajes son directamente relacionadas con el sistema que opera el servidor de la página web. Los lenguajes de programación y tecnologías habituales para Backend son PHP, NodeJS, Python, .NET, e incluye también entornos de bases de datos, como MySQL, PostgreSQL, SQL Server...

2.8 API

El término API es una abreviatura de Application Programming Interfaces, que en español significa interfaz de programación de aplicaciones.

La API es la interfaz que permite a distintas aplicaciones comunicarse entre sí y compartir datos entre ellos.

2.9 Estado del Arte

Image Segmentation Using Deep Learning: A Survey El artículo es una revisión extensa y detallada de los algoritmos de segmentación de imágenes basados en modelos de aprendizaje profundo, que han logrado un rendimiento impresionante en diversas tareas de segmentación, siendo agrupados en 10 categorías basadas en sus arquitecturas de modelos, dichos modelos fueron creados para la segmentación de imágenes a una función en específica. Las 10 categorías exploradas en el artículo son las siguientes:

- 1. Fully Convolutional Models o FCN, este modelo se ha aplicado en diversos problemas de segmentación, como la segmentación de tumores cerebrales y la segmentación de lesiones cutáneas.
 - 2. CNNs With Graphical Models, este modelo fue usado para el desafío de conjunto de datos PASCAL VOC2 obteniendo resultados muy buenos.
 - 3. Encoder-Decoder Based Models, este tipo de arquitectura de codificador-decodificador es muy utilizado en la segmentación de imágenes médicas, la más conocida es el modelo U-net para segmentar eficazmente las imágenes de microscopía biológica.
 - 4. Multiscale and Pyramid Network Based Models.este tipo de arquitectura es el análisis multiescala.
 - 5. R-CNN Based Models, el modelo más famoso de una R-CNN fue propuesta por He et al. Mask R-CNN, detectando eficientemente los objetos en una imagen y generando simultáneamente una máscara de segmentación de alta calidad para cada instancia.
-

- 6. Dilated Convolutional Models, Las convoluciones dilatadas han sido muy populares en el campo de la segmentación en tiempo real.
- 7. RNN Based Models, El modelo más popular basado en RNN es el ReSeg usado principalmente para la clasificación de imágenes.
- 8. Attention-Based Models.
- 9 Generative Models and Adversarial Training
- 10. CNN Models With Active Contour Models, este modelo abordó el problema de segmentación del ventrículo cardiaco. [27]




Figura 2.27: Modelo de segmentación semántica basado en la atención.

Breast Cancer Detection Using Convolutional Neural Networks El artículo presenta un modelo de detección de cáncer de mama basado en CNN que detecta anomalías en la masa y clasificarlas en benignas y malignas mediante mamografías, obtuvieron diversas fuentes para la base de datos y tener un volumen de entrenamiento mediano para el entrenamiento de su red basado en CNN, dichos datos obtuvieron del:

- St. Gabriel Hospital
- Grum Hospital

- Korea Hospital
- Betezatha Hospital
- Kadisko Hospital
- Pioneer Diagnostic Center

Se diseñó una arquitectura CNN para la extracción de características, para la detección de anomalías en la masa mamaria. El modelo fue entrenado y evaluado a través de las imágenes MG. El modelo propuesto logró una precisión de detección precisión de hasta el 91,86% , una sensibilidad del 94,67% y un AUC-ROC del 92,2%. [31]




Figura 2.28: Estructura de la arquitectura de detección del cáncer de mama.

Estado del arte				
	Autores	Año	Título	Descripción
1	Jun Bai , Russell Posner , Tianyu Wanga , Clifford Yang , Sheida Nabavi	2021	Applying deep learning in digital breast tomosynthesis for automatic breast cancer detection: A review	Se plantea desarrollar una detección de cáncer de mama a partir de imágenes de a tomosíntesis digital, el cual se trabajan las vistas craneocaudal y medio lateral oblicua todo mediante redes convolucionales y la segmentación mediante la U-net.[27]
2	Behrouz NiroomandFam, Alireza Nikravanshalmani & Madjid Khalilian	2021	Automatic breast mass detection in mammograms using density of wavelet coefficients and a patch-based CNN	Se aplica la densidad de los coeficientes de wavelet para identificar las regiones sospechosas y otra etapa para reducir la tasa de falsos positivos en la detección de cáncer de mama.[28]
3	Loannis Sechopoulos, , Jonas Teuwen , Ritse Mann	2021	Artificial intelligence for breast cancer detection in mammography and digital breast tomosynthesis: State of the art	Dada la similitud entre las dos modalidades de imágenes, mamografía y la tomosíntesis se aplican diferentes arquitecturas de red neuronal convolucional para el desarrollo de un sistema que funciones en ambas modalidades.[29]

Tabla 2.1: Estado del Arte

Estado del arte				
	Autores	Año	Título	Descripción
4	Shervin Minaee; Yuri Y. Boykov; Fatih Porikli; Antonio J Plaza; Nasser Kehtarnavaz; Demetri Terzopoulos	2021	Image Segmentation Using Deep Learning: A Survey	Se estudia los algoritmos de segmentación de imágenes basado en modelos de aprendizaje profundo, que han tenido un gran impacto y un rendimiento impresionante en los diversos trabajos de segmentación de imágenes. Se agrupan en categorías arquitectónicas como CNN y FCN, RNN, R-CNN.[30]
5	Jingjing Wang, Jun Gao, Jinwen Ren, Zhenye Luan, Zishu Yu, Yanhua Zhao, Yuefeng Zhao	2021	DFP-ResUNet:Convolutional Neural Network with a Dilated Convolutional Feature Pyramid for Multimodal Brain Tumor Segmentation	En este estudio se presenta un nuevo modelo de red neuronal DFP-ResUNet, para realizar la segmentación automática de ET, WT, TC subregiones de los tumores cerebrales.[31]
6	Simon Hadush, Yaacob Girmay, Abiot Sinamo, Gebrekirstos Hagos	2020	Breast Cancer Detection Using Convolutional Neural Networks	Presenta un modelo de detección de cáncer de mama basado en CNN que detecta anomalías masivas y las clasifica en benignas y malignas.[32]

Tabla 2.2: Estado del Arte

Estado del arte				
	Autores	Año	Título	Descripción
7	Muayad Sadik Croock , Saja Dhyaa Khuder, Ayad Esho Korial , Sahar Salman Mahmood	2020	Early detection of breast cancer using mammography images and software engineering process	Proponen el diseño de un sitio electrónico para la detección de cáncer de mama en las primeras etapas, para reducir la cola de espera en centros hospitalarios y la detección la realizan mediante un algoritmo de aprendizaje profundo.[33]
8	Alejandro Rodriguez, Ruiz, Kristina Lång, Albert Gubern,Merida, Mireille Broeders, Gisella Gennaro, Paola Clauser, Thomas H Helbich, Margarita	2019	Stand-Alone Artificial Intelligence for Breast Cancer Detection in Mammography: Comparison With 101 Radiologists	En este articulo se utiliza un sistema de IA para la detección de cáncer de mama en tomosíntesis el cual se compara con el análisis de los 101 radiólogos.[34]
9	Mugahed A.Alantaria, A.Al-masniz, MunTaek Choi, SeungMoo Han, Tae-Seong Kim	2018	A fully integrated computer-aided diagnosis system for digital X-ray mammograms via deep learning detection, segmentation, and classification	Se presenta un sistema CAD completamente integrado basado en aprendizaje profundo para la detección, segmentación y clasificación de las masas de mamografías, se adoptó un modelo de aprendizaje profundo llamado YOLO para detectar las regiones de masa.[35]

Tabla 2.3: Estado del Arte

Estado del arte				
	Autores	Año	Título	Descripción
10	Abien Fred M. Agarap	2018	On Breast Cancer Detection: An Application of Machine Learning Algorithms on the Wisconsin Diagnostic Dataset	Se presenta una aplicación de diferentes algoritmos de aprendizaje automático, incluido el modelo GRU-SVM para la detección de cáncer de mama.[36]
11	Mohammed A.Almasnia, Mugahed A.Al-antaria, Jeong MinParka, GeonGia, Tae-Yeon Kim, Patricio Rivera, Edwin Valarezo, Mun-Taek Choi, Seung-Moo Han, Tae-Seong Kim	2018	Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO based CAD system	Se plantea un sistema CAD basado en YOLO para la detección de masas mamarias y la clasificación del cáncer. El sistema CAD propuesto incorpora un enfoque CNN basado en ROI que capas convolucionales seguidas de redes neuronales totalmente conectadas para detectar la de la masa y distinguir los tipos de tumor: benigno o maligno.[37]
12	Rebecca Sawyer Lee, Francisco Gimenez, Assaf Hoogi, Kanae Kawai Miyake, Mia Gorovoy & Daniel L. Rubin	2017	A curated mammography data set for use in computeraided detection and diagnosis research	Se realiza en la base de datos DDSM un curado para el uso investigativo.[38]

Tabla 2.4: Estado del arte

3 Metodología

Para el desarrollo de este proyecto se plantea usar dos tipos de imágenes para la detección del cáncer de mama: imágenes de mamografía e imágenes histopatológicas. Para cada tipo de imagen se realiza la creación de un modelo basado en redes neuronales. Para la toma del modelo definitivo se harán comparaciones entre los dos mejores modelos resultantes con cada tipo imágenes, y será este el utilizado para realizar las predicciones del cáncer de mama. En la figura 3.1 se puede observar la metodología planteada.




Figura 3.1: Metodología planteada.

Se utiliza dos bases de datos para validar la metodología planteada: el CBIS-DDSM es una base de datos de imágenes de mamografía de película escaneada, contiene más de 1000 estudios de mamografía clasificada en casos malignos y benignos con verificación patológica verificada, en la figura 3.2a se visualiza una imagen de mamografía del conjunto de datos; Breast Histopathology Images es la base de datos de imágenes histopatológicas que presenta imágenes del carcinoma ductal invasivo (IDC) este tipo de cáncer más común de todos los cánceres de mama, en la figura 3.2b se visualiza una imagen de mamografía del conjunto de datos.




Figura 3.2: Conjunto de datos
Fuente: CBIS-DDSM y Breast histhopatology

El método propuesto para las imágenes de mamografías consta de varias fases en la figura 3.3 se muestra un resumen de la metodología aplicada a este tipo de imágenes.




Figura 3.3: Metodología aplicada a conjunto de imágenes de mamografía.

El segundo método propuesto es para las imágenes histopatológicas, en la figura 3.4 se muestra el resumen de la metodología aplicada en imágenes histopatológicas.




Figura 3.4: Metodología aplicada a conjunto de imágenes histopatológicas.

3.1 Preprocesamiento de Imágenes

En este capítulo se plantea el desarrollo del objetivo específico relacionado al acondicionamiento con técnicas de preprocesamiento las imágenes de mamografía e imágenes histopatológicas, El acondicionamiento es muy importante para lograr un buen resultado en la clasificación de las imágenes, porque se puede mejorar la imagen original, resaltando las determinadas características y eliminando otras que la ocultan. La finalidad es reducir los efectos del ruido que puedan producirse en las imágenes de mamografía e histopatología, las imágenes digitales están sujetas a distintos tipos de ruido. El ruido es el resultado de errores en el proceso de adquisición de imágenes, que dan lugar a valores de píxeles que no reflejan la intensidad real de la escena. El ruido puede entrar en la imagen de diferentes maneras, dependiendo de cómo se cree la imagen. En el caso de las imágenes de mamografías escaneadas a partir de una fotografía hecha en película, el grano de la película es una fuente de ruido. El ruido también puede ser el resultado de daños en la película, o que lo introduzca el propio escáner.

3.1.1 Cambio de formato imagen

La base de datos de imágenes de mamografía CBIS-DDSM están en un formato DICOM (Digital Imaging and Communications in Medicine) este formato se utiliza comúnmente para almacenar y transmitir imágenes médicas. Este formato de imágenes .dcm (extensión del formato DICOM) solo puede ser visualizado en un visor de imágenes médicas 3D como lo muestra en la figura 3.5, el visor de imágenes médicas que se

utilizo para visualizar las imágenes de mamografía en formato DICOM fue el software MicroDicom[39].




Figura 3-5: Visor de imagen médica MicroDicom.

Fuente: Autor

Para poder leer y visualizar este tipo de imagen médica en Python se instaló la librería de Pydicom [40], uno de los problemas de usar el formato DICOM son sus metadatos el cual contiene mucha información de píxeles, información médica como el id del paciente, nombre, enfermedad, localización, fecha, etc. Estos metadatos hacen el formato más pesado, al trabajar con el formato DICOM para clasificación sería un trabajo forzoso para la máquina. Se procede a realizar un cambio de formato a uno más ligero como es el PNG. Solo se necesita la visualización de la imagen en un formato ligero y que se pueda abrir en cualquier software, se empleó las librerías Pydicom, Pillow para mostrar y guardar la imagen a PNG, Numpy para manipular las matrices de la imagen y Os que nos permite acceder a las carpetas donde se encuentran las imágenes en formato DICOM. En la figura 3.6 se puede observar el proceso llevado a

cabo para la conversión de formato DICOM a PNG.




Figura 3.6: Conversión de formato DICOM a PNG.

3.1.2 Redimensionamiento de imágenes

Las dimensiones de las imágenes en el Data set DDSM no son las mismas para todas, se debe realizar un redimensionamiento de las imágenes ya convertidas a PNG a 256x256. Para cambiar el tamaño de las imágenes del Data set se usa la función `cv2.resize()` de la librería de OpenCv `cv2`.

3.1.3 Filtrado de Imágenes

Después de haber realizado el redimensionamiento de imágenes a 256x256, se debe filtrar las imágenes de la base de datos (CBIS-DDSM). Se observó que las imágenes presentan unas etiquetas como se visualiza en la Figura 3.4 y líneas blancas en las esquinas y bordes de las imágenes de mamografía.

En la figura 3.6 se puede observar el proceso llevado a cabo para eliminar las etiquetas y los bordes en blanco. Se cargan las imágenes de mamografía y se convierten en imágenes en escala de grises, se calcula el umbral global de la imagen ya convertida en escala de grises empleando el método Otsu el cual permite minimizar la varianza interclase de los píxeles blancos y negros pasados por el umbral, pero este umbral debe pasar de una escala de grises a una imagen binaria. Luego se debe medir las propiedades de las regiones “Área, centroides y BoundingBox”, esto ayudara a estimar las regiones de interés que se necesita omitir de la imagen final (Una imagen sin etiquetas), esto




Figura 3.7: Mamografía con ruido

haciendo uso de un boundingbox para encerrar ciertas áreas que no son de interés y mandarlas a cero (espacio de color negro).




Figura 3.8: Tratamiento de imágenes.





Para mejorar las imágenes de mamografía e histopatología se utiliza el filtro gaussiano y Ecualización adaptativa limitada del histograma. El filtro gaussiano se utiliza para el suavizado de imágenes y eliminación del ruido, la operación que realiza el filtro gaussiano es tomar el valor máximo que se muestra en píxeles y disminuye hacia los extremos más rápido cuando el valor del parámetro de desviación típica s es menor. El resultado será un conjunto de valores entre 0 y 1. Para transformar la matriz a una matriz entera, divide la matriz entera por el menor de los valores resultantes, la


ecuación que realiza el filtro gaussiano es la siguiente:

$$g(x,y) = e^{-(x^2 + y^2)/(2 * s^2)} \tag{3.1}$$

El CLAHE se encarga de mejorar el contraste de la imagen y la precisión de extracción, comprobando el histograma de la imagen y redistribuyendo el contraste para cambiar el contraste de la imagen y obtener más detalle en el contraste. Puede suprimir eficazmente la amplificación del ruido.[41]

En la siguiente tabla 1 se puede visualizar imágenes de mamografía original y con las técnicas de preprocesamiento aplicadas.

Imagen de mamografía Original	Imagen de mamografía con preprocesamiento
	
	



3.2 Aumentación de datos

En esta sección se va a realizar un aumento de datos, esta acción se realiza para expandir artificialmente el tamaño del conjunto de datos de entrenamiento mediante copias ligeramente modificadas de imágenes de mamografía e imágenes histopatológicas, esto nos ayudara a reducir el problema de sobreajuste (overfitting) al entrenar un modelo de aprendizaje automático.

Se cargaron las carpetas raíz de las imágenes de mamografía e imágenes histopatológicas a Google drive para ser cargadas a los servicios gratuitos de Google colab, en la figura 3.7 se observa la importación de los datos de Google drive a Google Colab.

```
from google.colab import drive
drive.mount('/content/drive')
%cd /content/drive/MyDrive/Tesis Datos
```

Figura 3.9: Carga de datos de Drive a Google Colab.

El conjunto de imágenes de mamografías cuenta con 1124 imágenes que pertenecen a dos tipos de tumor, tumor benigno (422 datos) y tumor maligno (422 datos), en la figura 3.8 se puede observar la distribución del conjunto de imágenes.




Figura 3.10: Distribución del conjunto de imágenes de mamografía.

El conjunto de imágenes histopatológicas cuenta con 1204 imágenes que pertenecen a dos clases, no presenta carcinoma ductal invasivo (617 datos) y si presenta carcinoma ductal invasivo (587 datos), en la figura 3.9 se puede observar la distribución del conjunto de imágenes.




Figura 3.11: Distribución del conjunto de imágenes histopatológicas.

(Jason Brownlee en abril 12, 2019 in Deep Learning for Computer Vision) explica que al entrenar modelos de redes neuronales de aprendizaje profundo en más datos puede resultar en modelos más hábiles, y las técnicas de aumento pueden crear variaciones de las imágenes que pueden mejorar la capacidad de los modelos de ajuste para generalizar lo que han aprendido a nuevas imágenes.[43]

Para aumentar los datos se usa la biblioteca de aprendizaje profundo de Keras ImageDataGenerator [44], esta librería nos ayudara a realizar el aumento de datos de forma automática mediante la creación de una instancia de la clase y la configuración de los tipos de aumento de datos se especifica mediante argumentos para el constructor de clases. Argumentos como:

- rotation_range
- width_shift_range
- height_shift_range
- brightness_range
- shear_range
- zoom_range
- horizontal_flip

- `vertical_flip`
- `rescale`

Para la aumentación de datos se usará la clase de `ImageDataGenerator` de Keras que permite realizar el aumento de imágenes mientras se entrena el modelo de red neuronal. `ImageDataGenerator` de Keras proporciona tres funciones diferentes para cargar el dataset de imagen en la memoria y generar lotes de datos aumentados:

- `.flow()`
- `.flow_from_directory()`
- `.flow_from_dataframe()`

El método utilizado para la aumentación de datos es el `flow_from_dataframe()` que toma el `Pandas DataFrame` y la ruta a un directorio y genera lotes de datos aumentados/normalizados. La clase de Keras `ImageDataGenerator` es la encargada de aplicar una normalización a las imágenes, la normalización cambia los datos de los píxeles a un rango de 0 a 1, con esto se logra mejorar los hiperparámetros de la red neuronal. El tamaño de lote se asigna en 32 esto indica que el entrenamiento se va ejecutando en lotes de 32 imágenes para evitar el sobreajuste al momento de entrenarse la red neuronal. `Class_mode` se establece en modo categórico ya que contamos con imágenes de tipo arreglo en 2 dimensiones.

La figura 3.9 muestra los datos aumentados de imágenes histopatológicas




Figura 3.12: Aumentación de imágenes histopatológicas.

La figura 3.10 muestra los datos aumentados de imágenes de mamografía




Figura 3.13: Aumentación de imágenes de mamografía.

3.3 Entrenamiento de Modelo de Red Neuronal Residual

Se usará una arquitectura de RESNET creada para la clasificación de cáncer de mama mediante imágenes de mamografía e imágenes histopatológicas, para validar que tipo de imagen puede predecir mejor el cáncer de mama, se plantea una red neuronal residual para la clasificación de imágenes, realizando ciertas operaciones de convolución y normalización, en este trabajo se aplica lo visto en el artículo de redes neuronales residuales (Kaiming He, 2015 Deep Residual Learning for Image Recognition) y se plantea una red neuronal de la siguiente manera como se muestra en la Figura 3.5.




Figura 3.14: Modelo final de Red Neuronal Residual para la clasificación de imágenes con cáncer.

Se realiza 3 bloques residuales en el modelo de red neuronal residual vista en la Figura 3.5, este bloque residual está conformado por un bloque de convolución y dos bloques de identidad, esta cantidad de bloques puede ser modificada si el problema a si lo requiera, porque la creación de este tipo de redes se basa en la prueba y error.




Figura 3.15: Bloque residual.

Se puede ver más a detalle el bloque de Convoluciones (Figura 3.7 a) y bloque de identidad (Figura 3.7 b), estas realizan operaciones una tras de otra como se puede ver sus respectivas figuras.

El bloque residual realiza una copia de la entrada porque una tiene que seguir el camino principal y otra tiene que seguir el camino de la función de identidad x que sería el camino corto, se realiza un filtro f_1, f_2, f_3 son las tres dimensiones de filtros que se va utilizar en las operaciones de convoluciones 2D, en el camino principal se van a realizar operaciones como Convolución 2D, Max Pooling, Batch Normalization, y funciones de activación Relu, el tamaño del filtro kernel será de $(3,3)$ en cada imagen, para que pueda extraer la información de la imagen moviéndose 3×3 , esto hará la imagen más pequeña para obtener los patrones característicos de la imagen. En el camino corto se usa la copia de la entrada para realizar las operaciones de convolución 2D, Max Pooling con una Batch Normalization, la operación de Max Pooling reduce las dimensiones de la imagen por eso tanto en el camino corto se aplica la operación de Max Pooling para mantener las dimensiones de las imágenes por ambas rutas, esto se realiza porque al final de los dos caminos se tienen que unir y aplicar por una función de activación Relu. En el bloque de identidad tiene menos operaciones que el bloque operacional el cual lo hace más fácil de programar, tiene operaciones de convolución 2D, Batch Normalization y funciones de activación Relu y como este bloque no tiene la operación de Max Pooling no hay necesidad de agregar operaciones en el camino corto porque sus dimensiones se mantienen iguales.

Después de haber creado el bloque residual, se procede a realizar la arquitectura final del modelo de red neuronal residual para la clasificación de cáncer de mama, se aplica




Figura 3.16: Bloques que conforman un bloque residual

las operaciones que se pueden ver en la Figura 3.3. Se ingresa los datos de entrada y sus dimensiones que son (256x256x3), luego de esto se aplica el ZeroPadding para rellenar una matriz de ceros a la entrada de la red. Se divide en fases, la primera fase son las operaciones principales para la creación de una red neuronal profunda que es la convolución2D, Batch Normalization, función de activación Relu y un Max Pooling.

- Se añade la capa de convolucion 2D, con filtros convolucionales de tamaño 32, que debe ser igual al tamaño del lote, y un tamaño de filtro = (3,3), que son los filtros kernels para que la red vaya extrayendo la información de cada imagen moviéndose 3X3 en la imagen. Se usa un paso (stride) igual a (2,2) lo que reduce las dimensiones espaciales a la mitad. La razón para colocar un número pequeño de filtros convolucionales de 32 es detectar bordes y líneas de las imágenes de mamografía e imágenes histopatológicas
- BatchNormalization es la normalización por lotes método utilizado para hacer el entrenamiento de la red neuronal residual sea más rápido, aplicando una trans-

formación que mantiene la salida media cerca de 0 y la desviación estándar de salida cercana a 1. El axis para la normalización fue definido en 3.

- MaxPooling es la capa donde se reducirá a la mitad las dimensiones de las imágenes, pero manteniendo la profundidad con un `pool_size= (3,3)` este es tamaño de ventana sobre el cual tomar el máximo. tomará el valor máximo sobre una ventana de agrupación de 3x3.

Luego se llama las funciones de `res_block` para las siguientes fases, que son 3 bloques residuales, luego se aplica un `AveragePooling2D` el cual reducirá las dimensiones espaciales mediante un `pool_size(2,2)` tomando el valor promedio sobre una ventana de agrupación 2x2, para pasar a la capa final donde se aplanan toda la información en un macro vector con la capa `Flatten`. Se agrega varias capas densas con cierta cantidad de neuronas `Dense` (número de neuronas, `activation = 'relu'`), esto para agregar a la red la cantidad de neuronas y capas que aprenderán las diferencias de la capa aplanada y determinar la similitud entre imágenes a partir del valor de los píxeles, se usa la función de activación `relu` porque los valores datos de imágenes de entrada corresponden a píxeles de valor positivo, y capas de `Dropout` el cual nos permitirá desactivar cierto porcentaje de neuronas de forma aleatoria lo que obligara a la red aprender los modelos de una manera más eficaz y no aprenda de los datos y gracias a esto disminuir el `overfitting`, la cual en cada época se desconectara el 20% de las conexiones de neuronas con `Dropout(0.2)`, con el fin que la red neuronal residual no se aprenda de memoria los datos de entrada y no tomar solo una ruta para clasificar las dos clases de tumor o carcinoma de mama si no que permita generalizar los datos de entrada y tomar varias rutas para una mejor clasificación. Al final de la red neuronal residual se usaron dos neuronas de salida con función de activación `sigmoid`, cada neurona arrojará un porcentaje y la función de activación `sigmoid` se encargará de determinar la neurona con mayor porcentaje de activación y asignará un valor con respecto a las dos clases en este caso con los datos de CBIS- DDSM Cáncer maligno o Benigno y en caso de la Breast Histopathology Images Cancer presenta cáncer ductal invasivo o no presenta cáncer ductal invasivo.

Aplicamos la función de activación Rectified Linear Unit (ReLU) en cada capa convolucional. Una función de activación que convierte la suma ponderada de entrada en la salida de ese nodo, la función de unidad lineal rectificada se utiliza en las capas ocultas de la red neuronal residual. Matemáticamente, ReLU se representa por:

$$f(z) = \max(0, z) \quad (3.2)$$

Donde z es la entrada, cuando z es negativo o igual a 0, transforma la entrada negativa en 0. Cuando la entrada es mayor que 0, entonces la salida será 1. Así que la derivada de ReLUs será:

$$f'(z) = \begin{cases} 1 & \text{for } z \geq 0 \\ 0 & \text{for } z < 0 \end{cases} \quad (3.3)$$

En el aprendizaje automático utilizamos la función de pérdida para calcular el error entre los valores predichos por el algoritmo y los valores de las clases verdaderas, en el caso de las imágenes de mamografía (Tumor maligno o Benigno) y en las imágenes histopatológicas (Si presenta IDC o No presenta IDC). A continuación, este error se minimiza utilizando cualquier método de optimización. En esta red se utilizó la función de pérdida Cross Entropy ya que se está realizando clasificación binaria en las imágenes de mamografía e imágenes histopatológicas por lo que utilizamos la entropía cruzada binaria. En la entropía cruzada binaria se calcula entre 0 y 1. Matemáticamente se representa como un:

$$J(z) = [y \log P(y) + (1 - y) \log(1 - P(y))] \quad (3.4)$$

En las redes neuronales profundas, aplicamos diferentes métodos de optimización ajustando parámetros como pesos y tasas de aprendizaje para reducir la pérdida. En esta red se utilizó el optimizador Adaptive momento (Adam). El optimizador Adam es una combinación de RMSprop y Descenso Gradiente Estocástico con momento. m y v representan los dos momentos, siendo m el que modela la media de los gradientes a lo largo del tiempo, mientras que v hace lo mismo con la varianza. β_1 es igual, en la mayoría de los casos, a 0.9, mientras que β_2 casi siempre se fija en 0.99

$$\begin{aligned} m &= \beta_1 * m + (1 - \beta_1) * \Delta W \\ v &= \beta_2 * v + (1 - \beta_2) * \Delta W^2 \\ W &= W - \frac{\alpha * m}{\sqrt{v} + \epsilon} \end{aligned}$$

Figura 3.17: Optimizador Adam.

3.4 ResNet50

En esta sección se plantea hacer uso de la Resnet50 el cual se planteó usar porque a medida que las redes neuronales se hacen más profundas, tiende a ocurrir el problema del desvanecimiento del gradiente que afecta negativamente a la red neuronal, el desvanecimiento del gradiente es la retropropagación hacia atrás el cual hace que el gradiente sea más pequeño y la resnet50 incluye la función de omisión de conexión que permite el entrenamiento de cierto número de capas sin el desvanecimiento del gradiente. Los pesos que utilizara la arquitectura de Resnet50 es la de Imagenet, este contiene 11 millones de imágenes y más de 20.000 categorías entrenadas, categorías que representan clases de objetos, tales como animales, coches, electrodomésticos etc. La Resnet50 es una red ya entrenada lo que se necesita realizar es una transferencia de aprendizaje con las bases de datos anteriormente descargados. En la figura 2.15 se aprecia la arquitectura de la Resnet50. En el siguiente código se importa el modelo de Resnet50 con `keras.applications.ResNet50V2` usando el peso de imagenet este peso se descargará automáticamente al crear la instancia del modelo y será almacenada en `keras/models` y configurar el formato de entrada en este caso para el CBIS-DDSM una entrada (256,256,3) y para la base de datos del Breast Histopathology Images una entrada (224,224,3), al cargar el modelo el argumento `"include_top=False"` se estableció en falso para no conectar las capas densas de la parte superior de la red, estas capas densas interpretan los patrones encontrados para clasificar entre los millones de parámetros de las cuales fueron entrenadas. Debido a esto, eliminar las capas densas con `"include_top=False"` nos permite definir el tamaño de la entrada el cual ya se estableció para las bases de datos, y agregar la cantidad de capas y neuronas para la clasificación del cáncer de mama. Al cargar los datos de entrada al modelo se aplicará un `keras.layers.GlobalAveragePooling2D()` el cual este eliminará las dimensiones espaciales y `Average` tomará el valor medio de cada canal. Para el Breast Histopathology Images al final de la red se usó una sola neurona de salida con una función de activación `sigmoid`. para guardar un modelo o pesos de la red al momento de entrenarse, `Clasificador_IDC.h5` es el nombre asignado para el modelo y el formato el cual se va a guardar para usarlo más adelante es el `h5` que es un formato de datos jerárquicos.

3.5 U-net

En esta sección se realiza el código de la segmentación de imágenes para la detección del cáncer de mama usando la arquitectura Unet, para la construcción del modelo U-net se usó como referencia el modelo de Olaf Ronnerberger, Philipp Fischer y Thomas Brox del artículo U-Net: Convolutional Networks for Biomedical Image Segmentation.

Esta arquitectura creada consta de cuatro partes muy importantes para la construcción del modelo U-net, como se muestra en la figura 3.18

- El bloque convolucional

- El bloque de encoder
- Cuello de botella
- El bloque de decoder




Figura 3.18: Modelo U-net.

En el bloque convolucional será constituida por 6 capas, en la figura 3.13 se puede apreciar las capas de manera secuencial, la primera será la convolucion2D, con un tamaño de kernel de 3×3 , luego un relleno de izquierda a derecha usando el argumento "padding = same", en la segunda capa se le agrega una capa de normalización y una función de activación relu ya que estabiliza su entrenamiento y ayuda a mejorar su rendimiento y se repite el mismo conjunto de capas, terminando con la construcción del bloque convolucional.




Figura 3.19: Bloque convolucional

Luego se implementa el bloque de encoder, en la figura 3.14 se aprecia la estructura del bloque de encoder, este bloque de encoder usara el bloque de convolución como una de sus capas, esto quiere decir que realizara las mismas operaciones que el bloque de encoder previamente creado, y se le añade una capa de operación de agrupación máxima 2D con esto se busca reducir a la mitad las dimensiones de las capas convolucionales de 2, pero manteniendo la profundidad con un tamaño de (2,2) con el argumento `MaxPool2D((2, 2))`.




Figura 3.20: Bloque convolucional.

Se realizara la implementación del bloque de decoder, en la figura 3.15 se aprecia la estructura del bloque de decoder, este bloque tomaría el mapa de características de entrada anterior (el del cuello de botella), como el bloque de decoder es un bloque ascendente se tendrá que utilizar una capa de convolución de transposición 2D y en su argumento tendrá un "strides=2" porque se quiere aumentar la muestra por un factor de dos, la siguiente capa es la concatenación de las salida X de la convolución de transposición y como último se utiliza el bloque de convolución para tener listo el bloque de decoder.




Figura 3.21: Bloque convolucional.

Al tener los bloques de convolución, encoder y decoder ya creados se procede a construir el modelo U-net, esta toma como entrada el `input_shape` de las imágenes en este caso (256,256,3), las primeras 4 capas del modelo U-net es del bloque de encoder y el número de filtros se duplicará en cada bloque de encoder, luego de esto se realiza la capa de cuello de botella.

Al final se hace uso del bloque de decoder usando 4 capas de estas disminuyendo el número de filtros a la mitad secuencialmente.

se crea una función para cargar las imágenes de la base de datos y poder realizar una división entre los datos de entrenamiento, validación y test, esta división de datos fue del 80% para los datos de entrenamiento que corresponde a 899 imágenes y máscara de la base de datos y un 10% y 10% para los datos de validación y test correspondiendo a 112 imágenes y máscara respectivas.

3.6 Selección de métricas de clasificación

para evaluar el rendimiento del modelo de aprendizaje automático de este trabajo se emplea la matriz de confusión. Su objetivo es estimar la precisión de la generalización del modelo a datos futuros.

Una matriz de confusión es una representación matricial de los resultados de predicción de cualquier prueba binaria. Suele utilizarse para describir el rendimiento del modelo de clasificación en un conjunto de datos de prueba cuyos valores verdaderos se conocen. En la figura 3.28 se puede apreciar la matriz de confusión con sus respectivas operaciones.

- True Positives (TP)
- Verdaderos Negativos (TN)
- False Positives (FP)
- False Negatives (FN)

$$Precision = \frac{\# \text{ of true positives}}{\# \text{ of true positives} + \# \text{ false positives}}$$

$$Recall = \frac{\# \text{ of true positives}}{\# \text{ of true positives} + \# \text{ of false negatives}}$$

$$F1 \text{ Score} = 2 * \frac{Precision * Recall}{Precision + Recall}$$

		Predicción	
		Positivos	Negativos
Observación	Positivos	Verdaderos Positivos (VP)	Falsos Negativos (FN)
	Negativos	Falsos Positivos (FP)	Verdaderos Negativos (VN)

Figura 3.22: Matriz de confusión.

Fuente: Health Big Data

3.7 Selección del mejor modelo de red neuronal y predicción de imágenes con cáncer de mama

El modelo seleccionado para la clasificación del cáncer de mama de los dos conjuntos de imágenes, fue quien presento mejor métricas en el entrenamiento, en el caso de la base de datos del CBIS-DDSM es la red residual, el conjunto de datos del Breast Histopathology Images usara el modelo de inteligencia artificial de la resnet50, Se selecciona la mejor red de las dos, después de haber seleccionado el mejor modelo se procede a guardar en formato .h5 de datos jerárquicos (HDF) que se utiliza para almacenar una gran cantidad de datos. Se procede a cargar una imagen nueva, se redimensiona y se cambia el valor de píxeles de 0 y 255 a 0 y 1 normalizando la imagen, para luego realizar la predicción, todo este proceso se lleva a cabo en la figura 3.23




Figura 3.23: Selección y predicción del mejor modelo de red neuronal.

Fuente: Autor

3.8 Página Web

En este capítulo se plantea la exposición del objetivo específico relacionado a la interfaz gráfica para la visualización del modelo de Inteligencia Artificial creado para la clasificación de cáncer de mama. El desarrollo de esta página web surge por la necesidad de brindar una mejor experiencia y fácil acceso a los médicos para poder clasificar el cáncer de mama de manera rápida y sencilla.

Se requiere de una plataforma que permita realizar la validación de cáncer de mama de un paciente, tener acceso a información sobre el cáncer de mama y tener la información de contacto.

3.8.1 Diseño de la página web

Se planteo un diseño sencillo para el inicio de la página web, que es lo principal que verán las personas que tendrán acceso a esta.

En la siguiente figura 3.24 se desarrolla la página web mediante HTML, nos proporciona la estructura básica de los sitios, que es mejorada por otras tecnologías como CSS y JavaScript. CSS se utiliza para controlar la presentación, el formato y el diseño. JavaScript se utiliza para controlar el comportamiento de diferentes elementos y Vercel es una plataforma en la nube para sitios estáticos y funciones sin servidor que se adapta al flujo de trabajo, permite alojar sitios web y servicios web que se implementan instantáneamente.




Figura 3.24: Desarrollo de Pagina Web.

Fuente: Autor

En la figura 3.25 se aprecia el diseño de la página web, cuenta con la sección de información, contiene información importante sobre el cáncer de mama. Sección de contacto, contiene información de datos personales y la sección más importante donde se aloja

los servicios de backend donde se puede subir la imagen para predecir el cáncer de mama.




Figura 3.25: Diseño de página web.

Fuente: Autor

3.8.2 API

A continuación, se realizará el desarrollo de la Api en el micro framework de Flask, se carga las librerías de flask y de machine learning para poder utilizar el modelo entrenado y guardado con el formato .h5, este modelo será llamado desde la carpeta raíz y se procede a crear un código que permita subir una imagen y use los pesos guardados de la red ya entrenada para poder predecir si la imagen sea de mamografía o imagen histopatológica tiene cáncer o no. En la figura 3.26 y 3.27 se visualiza el código que es implemento en flask para la creación de la API.



```
1  #import flask
2  from flask import Flask, request, jsonify
3  #import os
4  from os import getcwd
5  from sys import path
6  path.append(".")
7  #import config
8  from config.default import Config
9  #import kera
10 # Keras
11 from keras.models import load_model
12 from keras.applications.imagenet_utils import preprocess_input
13 from PIL import Image
14 import numpy as np
15 import cv2
16 #app initialization
17 app = Flask(__name__)
18 #app config
19 app.config.from_object(Config)
20
21 #Load model
22 MODEL_PATH = 'Clasificador_IDC.h5'
23 #Loading models
24 model = load_model(MODEL_PATH)
25
26 PATH_FILES = getcwd() + "/storage/"
```

Figura 3.26: API

```
1 def predecir(date):
2
3     image = cv2.imread(str(date))
4
5     image_fromarray = Image.fromarray(image, 'RGB')
6     resize_image = image_fromarray.resize((256, 256))
7     expand_input = np.expand_dims(resize_image,axis=0)
8     input_data = np.array(expand_input)
9     input_data = input_data/255
10
11     pred = model.predict(input_data)
12     if pred >= 0.5:
13         return "Si presenta cancer de mama"
14     else:
15         return "No presenta cancer de mama"
16
17 @app.post("/upload")
18 def upload_file():
19     try:
20         file = request.files['file']
21         file.save(PATH_FILES + file.filename)
22         return jsonify(predecir(PATH_FILES + file.filename))
23     except FileNotFoundError:
24         return {"failed": "okay"}
25
26 if __name__ == '__main__':
27     app.run()
```

Figura 3.32: API

3.8.3 Consumo de la API

Para poder consumir el servicio de una Api de machine learning primero se debe subir el api a un servicio de la nube, en nuestro caso se usará la instancia EC2 de AWS para poder implementar una API de flask de machine learning de Tensorflow entrenada desde cero.




Figura 3.33: Comunicación entre la API de flask por medio del protocolo SSH a los servicios de AWS .

Con una cuenta creada en Amazon Web Services, se debe crear una instancia EC2 elcual este es un servidor virtual en la nube, se debe lanzar una instancia y configurarla




Figura 3.34: EC2 AWS.

Fuente: Autor

Se debe elegir una maquina AMI que es elegir un sistema operativo para el servidor, el sistema operativo seleccionado fue el Ubuntu Server 20.04 LTS de 64 bits, y se procede a elegir la instancia como t2.micro como opción gratuita, se modificara las particiones de memoria y se aumentara el almacenamiento interno de esta instancia. Se debe crear un nuevo par de claves para conectarse a la instancia de forma segura y remota con el protocolo SSH. En la siguiente figura se puede observar que la instancia se encuentra creada.




Figura 3.35: Instancia EC2.

Fuente: Autor

Se necesita del software MobaXterm para realizar la conexión de forma local con la instancia de AWS EC2 e instalar las librerías en el entorno virtual de AWS, pero para poder acceder a la instancia EC2 por medio del protocolo SSH se debe insertar la clave generada y descargada al momento de haber creado la instancia de AWS e ingresar el nombre de usuario.




Figura 3.36: MobaXterm.

Fuente: Autor

Después de haber instalado todas las dependencias de python se requiere modificar el `app.run()` el cual es el arranque de la API indicando el host en '0.0.0.0' para que cualquier dirección funcione y puerto = 80 (HTTP), y ya se tiene la API montada en un servidor de AWS.

4 Resultados

En el capítulo se logró realizar redes neuronales capaz de detectar el cáncer de mama mediante imágenes histopatológicas y de mamografías, para la identificar de que tipo de imágenes brinda un mejor resultado para la detección de cáncer de mama.

4.1 Filtros aplicados y CLAHE

Se aplicaron filtros lineales como filtro gaussiano y de la media con el fin de suavizar la imagen, por último, se realizó una transformación de la intensidad de las imágenes, usando ecualización de histograma adaptativo de contraste limitado




Figura 4.1: Filtros aplicados.

Se eligió el filtro gaussiano debido a la buena disminución de la nitidez, aumento de borrosidad, pérdida de detalles y produce un suavizado más uniforme que el de la

media, y la ecualización de histograma adaptativo de contraste limitado para subir el contraste a la imagen y resaltar los bordes de la imagen que son importantes para la extracción de características.

4.2 Datos Aumentados

Los datos aumentados para los dos tipos de imágenes con ImageDataGenerator son las siguientes, para las imágenes histopatológicas se genera 32 imágenes por cada iteración, el entrenamiento tiene 33 iteraciones, validación 4 iteraciones y el test 2 iteraciones, en la figura 4.3 se muestra el conjunto de datos aumentados para el entrenamiento de las redes.




Figura 4.2: Datos aumentados de las imágenes histopatológicas.

Para las imágenes de mamografía se generan 32 imágenes por cada iteración, el entrenamiento cuenta con 26 interacciones, validación 4 y test 2 iteraciones, en la figura 4.3 se muestra el conjunto de datos aumentados para el entrenamiento de las redes




Figura 4.3: Datos aumentados de las imágenes de mamografía.

4.3 Resultados De Entrenamiento De Las Redes Neuronales

Se muestran los resultados correspondientes de los entrenamientos de cada red neuronal (Red Neuronal Residual y ResNet50), se escoge el mejor modelo de red neuronal para desplegar la API del modelo de aprendizaje automático y ser consumida por la página web.

La estructura de la red neuronal residual que se usara para ambas conjunto de imágenes es la siguiente, con más de 39 millones de parámetros entrenables y 42,368 parámetros que no se pueden entrenar, como se puede apreciar en la figura 4.4.

res_5_identity_2_c (Conv2D)	(None, 3, 3, 2048)	1050624	activation_109[0][0]
bn_5_identity_2_c (BatchNormali	(None, 3, 3, 2048)	8192	res_5_identity_2_c[0][0]
add_35 (Add)	(None, 3, 3, 2048)	0	bn_5_identity_2_c[0][0] activation_107[0][0]
activation_110 (Activation)	(None, 3, 3, 2048)	0	add_35[0][0]
Averagea_Pooling (AveragePoolin	(None, 1, 1, 2048)	0	activation_110[0][0]
flatten_2 (Flatten)	(None, 2048)	0	Averagea_Pooling[0][0]
dense_10 (Dense)	(None, 4096)	8392704	flatten_2[0][0]
dropout_8 (Dropout)	(None, 4096)	0	dense_10[0][0]
dense_11 (Dense)	(None, 2048)	8390656	dropout_8[0][0]
dropout_9 (Dropout)	(None, 2048)	0	dense_11[0][0]
dense_12 (Dense)	(None, 1024)	2098176	dropout_9[0][0]
dropout_10 (Dropout)	(None, 1024)	0	dense_12[0][0]
dense_13 (Dense)	(None, 512)	524800	dropout_10[0][0]
dropout_11 (Dropout)	(None, 512)	0	dense_13[0][0]
dense_14 (Dense)	(None, 512)	262656	dropout_11[0][0]
dropout_12 (Dropout)	(None, 512)	0	dense_14[0][0]
dense_15 (Dense)	(None, 256)	131328	dropout_12[0][0]
dropout_13 (Dropout)	(None, 256)	0	dense_15[0][0]
dense_16 (Dense)	(None, 2)	514	dropout_13[0][0]
=====			
Total params: 39,740,802			
Trainable params: 39,698,434			
Non-trainable params: 42,368			

Figura 4.4: Estructura de red residual compilada parte final.

La estructura de la Resnet50 que se usara para ambos conjuntos de imágenes, con más de 23 millones de parámetros entrenables y 2,049 parámetros que no se pueden entrenar, como se puede apreciar en la figura 4.5.

```

Downloading data from https://storage.googleapis.com/tensorflow/keras-94674944/94668760 [=====] - 3s 0us/step
Model: "functional_7"

```

Layer (type)	Output Shape	Param #
input_5 (InputLayer)	[(None, 224, 224, 3)]	0
resnet50v2 (Functional)	(None, 7, 7, 2048)	23564800
global_average_pooling2d (G1	(None, 2048)	0
dropout_12 (Dropout)	(None, 2048)	0
dense_15 (Dense)	(None, 1)	2049

```

=====
Total params: 23,566,849
Trainable params: 2,049
Non-trainable params: 23,564,800
=====

```

Figura 4.5: Estructura de Resnet50 para el Breast Hisopathology Images.**Fuente: Autor**

4.3.1 Red Neuronal Residual y ResNet50 para imágenes de mamografía

La mejor red entrenada para la clasificación de cáncer de mama mediante imágenes de mamografía es la red neuronal residual, en la siguiente tabla se puede apreciar los mejores valores de perdida y precisión conseguidos por ambas redes neuronales, que cumplió con el propósito de verificar cual es la mejor red para la clasificación de cáncer de mama mediante imágenes de mamografía.

Conjunto de imágenes de mamografía				
Red Neuronal	Precisión	Perdida	V_Precisión	V_perdida
Red Neuronal Residual	92.34%	6.4%	71.88%	27.23%
ResNet50	99.55%	4.25%	65.21%	66.5%

Red Neuronal Residual

En la gráfica de la figura 4.4 se visualiza la precisión de entrenamiento y validación durante 100 épocas.




Figura 4.6: Precisión de entrenamiento y validación de la red residual con las imágenes de mamografía.

En la gráfica de la figura 4.4 se visualiza las pérdidas de entrenamiento y validación durante 100 épocas.




Figura 4.7: Pérdidas de entrenamiento y validación de la red residual con las imágenes de mamografía.

ResNet50

En la gráfica de la figura 4.4 se visualiza la precisión de entrenamiento y validación durante 50 épocas.




Figura 4.8: Precisión de entrenamiento y validación de la Resnet50 con las imágenes de mamografía.

En la gráfica de la figura 4.4 se visualiza las pérdidas de entrenamiento y validación durante 100 épocas.




Figura 4.9: Pérdidas de entrenamiento y validación de la Resnet50 con la base de datos del CBIS-DDSM.

En ambas redes empleadas para la detección de cáncer de mama sufrieron de subajuste debido a que la curva de validación estuvo por debajo de, este problema se debe a varios factores, el bajo volumen de datos, la cantidad de mamografías para entrenar los modelos no son lo suficientemente grandes para poder evitar el subajuste, con un conjunto de entrenamiento más grande en los modelos, estos no se podrán subajustar a las muestras y se verá obligado a generalizar para obtener mejores resultados, también de asegurarnos de tener imágenes de cáncer de mama relevantes y limpias. Otro problema que influyó en subajuste de los modelos

fue la complejidad de las imágenes.

Una observación general sobre los dos modelos es que estos aprendieron de los datos de entrenamiento, pero en la validación no alcanzaron porcentajes óptimos, es una clara señal de subajuste.

La red residual presento mejor precisión a las 100 épocas de entrenamiento con un 71.88% y una pérdida del 27.3%, la ResNet se entrenó con 50 épocas presentaba una precisión por encima del 60% pero cada vez que avanzaba las épocas de aprendizaje los valores de perdida incrementaban.

4.3.2 Red Neuronal Residual y ResNet50 para imágenes histopatológicas

La mejor red entrenada para la clasificación de cáncer de mama mediante imágenes histopatológicas es la ResNet50, en la siguiente tabla se puede apreciar los mejores valores de perdida y precisión conseguidos por ambas redes neuronales, con el fin de obtener la mejor red.

Conjunto de imágenes histopatológicas				
Red Neuronal	Precisión Con la data de entrenamiento	Perdida con la data de entrenamiento	V_Precisión	V_perdida
Red Neuronal Residual	94.84%	12.97%	96.52%	13.02%
ResNet50	90.47%	27.62%	97.39%	19.21%


Red Neuronal Residual

Figura 4.10: Precisión de entrenamiento y validación de la red residual con las imágenes histopatológicas.




Figura 4.11: Perdidas de entrenamiento y validación de la red residual con las imágenes histopatológicas.

ResNet50




Figura 4.12: Precisión de entrenamiento y validación de la Resnet50 con las imágenes histopatológicas.




Figura 4.13: Pérdidas de entrenamiento y validación de la Resnet50 con las imágenes histopatológicas.

Ambas redes obtuvieron resultados muy buenos, pero al ResNet presento una mejor precisión en las pérdidas de validación y por esto fue considerado el mejor modelo para identificar cáncer de mama mediante imágenes histopatológicas. Ambas redes entrenadas con 50 épocas de aprendizaje, a la ResNet50 le tomo más de 30 épocas presentar un porcentaje igual o superior al 90% de precisión, a la red neuronal residual le basto con 10 épocas tener una precisión por encima del 90% con valores de perdida por debajo del 20%.

La red neuronal residual en ciertas épocas presentó valores de precisión muy bajos con pérdidas muy altas, lo que hizo a la red muy inestable en las 50 épocas en la que se entrenó, todo lo contrario, a la ResNet50 que fue una red más estable desde el comienzo, y fue una de las razones por el cual se eligió la ResNet50 la red más ideal para la clasificación de cáncer de mama.

4.4 Predicción del cáncer de mama mediante matriz de confusión

La matriz de confusión nos permite la visualización del desempeño de la red para las imágenes histopatológicas y de mamografías, para las imágenes histopatológicas se usaron 60 imágenes para la validación de la red, obteniendo como verdadero positivos 25 imágenes que si presentan carcinoma ductal invasivo, y un falso positivo, para un acierto de 25/26 imágenes histopatológicas que presentan cáncer, para los casos que no presenta cáncer ductal invasivo se obtuvieron 32 imágenes como verdaderos negativos y 2 imágenes que fueron un falso negativo, 32/34 imágenes que no presentan cáncer de mama fueron acertadas mediante la red neuronal presentada en este trabajo. Se obtuvo unos resultados en la precisión muy excelentes en la primera tabla se puede apreciar el resultado.

	Predicción de carcinoma ductal invasivo		
		SI CDI	No CDI
	Positivos/Negativos	Si CDI	25
		No CDI	2
			32

$$precision = 0.961 \quad Recall = 0.961 \quad F1 \text{ Score} = 0.951$$

Para las imágenes de mamografía se usaron 58 imágenes para la validación, no se obtuvieron los resultados esperados debido a que la red neuronal residual presento un 71.88% en la validación en 100 épocas de aprendizaje, se obtuvo 14 verdaderos positivos y 15 como falsos positivos, para un acierto de 14/29 imágenes de mamografía que presentaron cáncer, para los casos que no presentan cáncer fueron 18 imágenes como verdaderos negativos y 11 imágenes de mamografía como falsos negativos, 18/29.

	Predicción de tumor maligno o benigno		
		Tumor maligno	Tumor benigno
	Positivo/Negativos	Tumor maligno	14
		Nivel Normal	11
			15
			18

$$precision = 0.5527 \quad Recall = 0.5517 \quad F1 \text{ Score} = 0.5522$$

4.3 Segmentación de imágenes

En la figura 4.26, se muestra la estructura del modelo implementado como el número de parámetros entrenables y no entrenables, en la figura se puede observar el número de tensores de salida.

batch_normalization_13 (BatchNorm	(None, 64, 64, 256)	0	conv2d_13[0][0]
activation_13 (Activation)	(None, 64, 64, 256)	0	batch_normalization_13[0][0]
conv2d_transpose_2 (Conv2DTrans	(None, 128, 128, 128)	131200	activation_13[0][0]
concatenate_2 (Concatenate)	(None, 128, 128, 256)	0	conv2d_transpose_2[0][0]
			activation_3[0][0]
conv2d_14 (Conv2D)	(None, 128, 128, 128)	295040	concatenate_2[0][0]
batch_normalization_14 (BatchNorm	(None, 128, 128, 128)	512	conv2d_14[0][0]
activation_14 (Activation)	(None, 128, 128, 128)	0	batch_normalization_14[0][0]
conv2d_15 (Conv2D)	(None, 128, 128, 128)	147584	activation_14[0][0]
batch_normalization_15 (BatchNorm	(None, 128, 128, 128)	512	conv2d_15[0][0]
activation_15 (Activation)	(None, 128, 128, 128)	0	batch_normalization_15[0][0]
conv2d_transpose_3 (Conv2DTrans	(None, 256, 256, 64)	32832	activation_15[0][0]
concatenate_3 (Concatenate)	(None, 256, 256, 128)	0	conv2d_transpose_3[0][0]
			activation_1[0][0]
conv2d_16 (Conv2D)	(None, 256, 256, 64)	73792	concatenate_3[0][0]
batch_normalization_16 (BatchNorm	(None, 256, 256, 64)	256	conv2d_16[0][0]
activation_16 (Activation)	(None, 256, 256, 64)	0	batch_normalization_16[0][0]
conv2d_17 (Conv2D)	(None, 256, 256, 64)	36928	activation_16[0][0]
batch_normalization_17 (BatchNorm	(None, 256, 256, 64)	256	conv2d_17[0][0]
activation_17 (Activation)	(None, 256, 256, 64)	0	batch_normalization_17[0][0]
conv2d_18 (Conv2D)	(None, 256, 256, 1)	65	activation_17[0][0]
Total params: 31,055,297			
Trainable params: 31,043,521			
Non-trainable params: 11,776			

Figura 4.14: Estructura del modelo U-net para la segmentación de imágenes.

Los resultados del entrenamiento del modelo U-net para la segmentación de imágenes no fue lo esperado, a este modelo se le implemento unas 200 épocas de aprendizaje las cuales solo tuvo 82 épocas al momento de entrenar esto debido al EarlyStopping el cual nos indica una parada temprana del modelo debido a que los valores de pérdida en la validación no mejoraban, el modelo tardo alrededor de 4 horas usando la Gpu T4 de kaggle con 82 épocas obteniendo porcentajes de pérdida del 26.61% y de precisión un 73.60% en el entrenamiento, los porcentajes de pérdida y precisión fueron demasiados malos para segmentar los tumores malignos y benignos, pérdida del 61.35% y una precisión del 24.64%. Esto debido al conjunto de datos que cuenta con calcificaciones: Macrocalcificaciones y Microcalcificaciones.

Las macrocalcificaciones se ven como grandes puntos o guiones blancos. Casi nunca son cancerosas y no requieren otros análisis ni seguimiento. Las microcalcificaciones aparecen como partículas blancas y finas, similares a granos de sal. Generalmente no son cancerosas, pero ciertos patrones pueden ser una señal temprana de cáncer.

Las calcificaciones mamarias son depósitos de calcio dentro del tejido de la mama. En una mamografía aparecen como manchas o partículas blancas. La mayoría de las veces, no son un signo de cáncer. Sin embargo, puede ser necesario revisar estas zonas con mayor cuidado según la apariencia que tengan en la mamografía, debido a esto la segmentación mediante el modelo U-net segmenta las regiones donde puede llegar a presentar calcificaciones.

Se optó por probar el modelo de segmentación U-net con otro tipo de imágenes no propuesta para validar el funcionamiento del modelo, el conjunto de datos que se utilizó es de imágenes de ultrasonido mamario, en la figura 4.15 se puede observar el ultrasonido mamario y su respectiva máscara original. El conjunto de datos ha recopilado imágenes de ultrasonido entre mujeres de entre 25 y 75 años de edad, cuenta con 780 imágenes en formato png estas imágenes se clasifican en tres clases: normales, benignas y malignas.




Figura 4.15: Ultrasonido y máscara respectiva.

En las métricas de entrenamiento esta base de datos alcanzo una precisión en el entrenamiento del 98.18% y una pérdida del 5%, esto quiero decir que el entrenamiento con la base de datos de ultrasonido mamario presento mejores métricas que la base de datos de imágenes de mamografía.








Figura 4.16: Gráfica de precisión y pérdida del modelo U-net con imágenes de ultrasonido mamario.

En la siguiente tabla se muestra los valores de precisión y pérdida en el entrenamiento y validación de los dos tipos de imágenes que proporcionan la máscara donde se ubica el tumor.


Segmentación U-net				
Base de datos	Precisión	Perdida	V_Precisión	V_perdida
CBIS-DDSM	73.60%	26.61%	18.64%	81.35%
Ultrasonido Mamario	98.18%	5%	82.52%	16.02%


4.3.1 Segmentación de imágenes aplicado al CBIS-DDSM



Mamografía	Mascara Original	Predicción de mascara
		

4.3.2 Segmentación de imágenes aplicado a ultrasonido mamario





4.4 Página Web

En la figura 4.17 se observa la página web creada por medio de html, css y Angular, totalmente desplegado en vercel, plataforma utilizada para desarrolladores frontend, que proporciona herramientas para la construcción, previsualización y despliegue de la página web a producción, la página web para la detección de cáncer de mama cuenta con un menú desplegable el cual nos permite revisar la información de distintos documentos sobre el cáncer de mama, síntomas, cuidado etc. También cuenta con el apartado de la Predicción que utiliza los servicios de un backend, servicio que fue consumido tras

haber hecho la comunicación de la API creada en flask por medio del protocolo SSH a los servicios de AWS para poder hacer validaciones sobre la detección del cancer de mama mediante imágenes de mamografías e imágenes histopatológicas y por último la sección de contacto.




Figura 4.17: Pagina web Inicio.

En la figura 4.18 se observa el menú principal de la página Web, un menú sencillo y de fácil navegación para el usuario, el menú está comprendido por 4 botones de navegación, el inicio, Información, API, Contacto.

Menu principal



Figura 4.18: Menú Principal.

En la figura 4.19 se observa el apartado de información, en esta sección se habla sobre el cáncer de mama y los tipos de cáncer de mama que existen y la sintomatología del cáncer de mama, información referenciada del national cancer institute.




Figura 4.19: Menú Principal.

En la figura se visualiza la sección API, esta sección utiliza los servicios de Backend y es la parte más importante del proyecto, el backend está destinado a administrar peticiones y solicitudes a la aplicación web, dichas solicitudes se reflejan en el entorno virtual creado en ec2 de AWS, con el fin de realizar las predicciones del cáncer de mama.




Figura 4.20: Predicción del cáncer de mama.

Por último, en la figura 4.21 se visualiza la sección de contacto personal.




Figura 4.21: Contacto.

5 Conclusiones

Se acondicionó con técnicas de preprocesamiento las imágenes de mamografía, esta base de datos cuenta con mamografías de películas escaneadas, sin haberle realizado un correcto preprocesamiento a las imágenes presentaron gran problema al momento de entrenar el modelo de red neuronal, por los bordes y esquinas blancas, uno de los principales problemas de esta base de datos fue la dirección inconsistente que enfrenta el seno lo cual implica que algunas mamografías miran hacia la izquierda y otras hacia la derecha, el cual complicó potencialmente el preprocesamiento de imágenes, el poco contraste de las mamografías fue el mayor problema de la base de datos, el entrenamiento de una red neuronal residual y una resnet50 para esta base de datos sin acondicionar no superó el 30-40% de precisión en la validación para la clasificación de cáncer de mama, esta clasificación mejoró al aplicar los filtros el filtro gaussiano y la ecualización de histograma adaptativo de contraste limitado para mejorar el contraste de las imágenes, superando el 30% de clasificación antes de ser preprocesado a un 72% en la red residual y un 65.1% de clasificación del cáncer de mama con la resnet50.

Se implementó la inteligencia artificial basada en redes neuronales convolucionales profundas, para identificar qué tipo de imágenes presenta mejores métricas en la validación para la clasificación de cáncer de mama, las imágenes implementadas que brindaron un soporte en este trabajo fueron: los tumores malignos y benignos por medio de mamografías; el carcinoma ductal invasivo mediante imágenes histopatológicas. Las redes neuronales convolucionales aplicadas en este trabajo fueron la resnet50 y la red neuronal residual, estableciendo a la red neuronal residual como la mejor red creada en este trabajo para la detección del cáncer de mama mediante mamografías y del mismo modo se establece a la resnet50 como la mejor red para la detección del carcinoma ductal invasivo, y como mejor tipo de imagen para la clasificación de cáncer de mama implementando de las redes previamente descritas fueron las imágenes histopatológicas.

Se validó los modelos entrenados mediante imágenes aportadas por las bases de datos y separadas del entrenamiento de las redes: imágenes de mamografías e imágenes histopatológicas. Se validaron estas imágenes con los mejores modelos de red neuronal entrenados, las imágenes de mamografías tuvieron un acierto de 32/58, un 55.2% de acierto lo cual indica que el modelo creado no es apto para la clasificación de cáncer de mama mediante mamografías, mientras que las imágenes histopatológicas tuvieron un acierto de 58/61, un 95.1% de acierto, un modelo muy apto para la clasificación del carcinoma ductal invasivo.

Se desarrolló una página web como interfaz gráfica para el uso adecuado de un especialista o persona común, con información acerca del cáncer de mama y acceso al libro de tesis para futuros trabajos, así mismo se accede al menú API para cargar nuevas imágenes desde la propia página web para validar por medio de imágenes compatibles el cáncer de mama, se desarrolló la API mediante flask acudiendo a librerías de machine,

que permitió la validación del modelo entrenado para clasificar, este consumo se realizó por medio de una instancia EC2 en AWS optando por servicios gratuitos el cual solamente permitió crear una instancia para un modelo de machine learning.

6 Trabajos futuros

- Suministrar imágenes histopatológicas de diferentes tipos de cáncer de mama a las redes neuronales, para la detección de varios tipos de cáncer de mama y tener un mayor impacto en beneficio del especialista y el paciente.
- Aumentar el conjunto de imágenes de mamografías para mejorar el entrenamiento de la red neuronal y poder implementar en un sitio web.
- Almacenar las imágenes de mamografías o imagen histopatológicas, por medio de una base de datos tales como Amazon Aurora o MySQL, con el fin de obtener un conjunto de datos grande.

7 Bibliografía

[1] Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A., Bray, F. (2021). Estadísticas mundiales del cáncer 2020: GLOBOCAN estima la incidencia y mortalidad en todo el mundo para 36 cánceres en 185 países. CA: una revista sobre el cáncer para médicos, 71(3), 209-249.

[2] ¿Qué es el cáncer de seno? (cancer.org) <https://www.cancer.org/es/cancer/cancer-de-seno/acerca/que-es-el-cancer-de-seno.html>.

[3] Rebecca Sawyer Lee, Francisco Giménez, Assaf Hoogi, Daniel Rubin (2016). Subconjunto de imágenes mamarias curadas de DDSM [Conjunto de datos]. El Archivo de Imágenes del Cáncer. DOI: <https://doi.org/10.7937/K9/TCIA.2016.7Oo2S9CY>.

[4] Cáncer de seno invasivo (IDC/ILC) (cancer.org) <https://www.cancer.org/es/cancer/cancer-de-seno/acerca/tipos-de-cancer-de-seno/cancer-invasivo-del-seno.html>.

[5] Torres, A. D. (1996). Procesamiento digital de imágenes. Perfiles Educativos, (72).

[6] ¿Qué es la inteligencia artificial (IA)? | Oracle Colombia.

[7] El concepto de neuronas artificiales (perceptrones) en las redes neuronales | por Rukshan Pramoditha | Hacia la ciencia de datos (towardsdatascience.com)

[8] El Naqa, I., Murphy, M. J. (2015). ¿Qué es el aprendizaje automático?. En machine learning en oncología radioterápica (pp. 3-11). Springer, Cham.

[9] Rouhiainen, L. (2018). Inteligencia artificial. Madrid: Alienta Editorial.

[10] Dave Gershgorin, «The Quartz guide to artificial intelligence: What is it, why is it important, and should we be afraid?», Quartz, 10 de septiembre de 2017.

[11] Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database. 2009 IEEE conference on computer vision and pattern recognition, 248–255.

[12] Hu, J., Shen, L., Sun, G. (2018). Squeeze-and-excitation networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 7132-7141).

-
- [13] Redes neuronales convolucionales - MATLAB Simulink (mathworks.com)
- [14] Red Neuronal Convolucional CNN - Diego Calvo
- [15] ¿Qué son las Redes Neuronales Convolucionales? | KeepCoding Tech School.
- [16] He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).
- [17] La Red Residual (Residual Network, ResNet) (cimat.mx).
- [18] Palomino, N. L. S., Concha, U. N. R. (2009). Técnicas de segmentación en procesamiento digital de imágenes. Revista de investigación de Sistemas e Informática, 6(2), 9-16.
- [19] Quintana, Aileen. (2019). Segmentacion de imagenes. 10.13140/RG.2.2.27974.52802. Interpretación cuantitativa/cualitativa de los datos presentes en una imagen utilizando herramientas matemáticas empleadas en técnicas de procesamiento de imágenes.
- [20] Ronneberger, O., Fischer, P., Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In International Conference on Medical image computing and computer-assisted intervention (pp. 234-241). Springer, Cham.
- [21] Aditti Mital (2019, June) Introduction to U-Net and Res-Net for Image Segmentation, Introduction to U-Net and Res-Net for Image Segmentation | by Aditi Mittal | Medium
- [22] Google Colab, <https://research.google.com/colaboratory/faq.html>
- [23] Qué es Python y por qué empezar a programar con este lenguaje (platzi.com)
- [24] “Información de TensorFlow disponible en su página oficial”: <https://www.tensorflow.org/about?h419>
- [25] “Información de Keras disponible en su página oficial”: <https://keras.io/about/>
- [26] Escuela IT. Materias. “Desarrollo web disciplinas enfocadas en el desarrollo de sitios y aplicaciones web”. En línea. 2021. Disponible en: (<https://escuela.it/materias/desarrollo-web>)
- [27] Bai, J., Posner, R., Wang, T., Yang, C., Nabavi, S. (2021). Applying deep learning in digital breast tomosynthesis for automatic breast cancer detection: A review. Medical image analysis, 71, 102049
-

[28] NiroomandFam, B., Nikravanshalmani, A. Khalilian, M. Automatic breast mass detection in mammograms using density of wavelet coefficients and a patch-based CNN. *Int J CARS* 16, 1805–1815 (2021). <https://doi.org/10.1007/s11548-021-02443-9>

[29] Sechopoulos I, Teuwen J, Mann R. Artificial intelligence for breast cancer detection in mammography and digital breast tomosynthesis: State of the art. *Semin Cancer Biol.* 2021 Jul;72:214-225. doi: 10.1016/j.semcancer.2020.06.002. Epub 2020 Jun 9. PMID: 32531273

[30] Croock, M. S., Khuder, S. D., Korial, A. E., Mahmmoud, S. S. (2020). Early detection of breast cancer using mammography images and software engineering process. *Telkomnika*, 18(4), 1784-1794.

[31] Hadush, S., Girmay, Y., Sinamo, A., Hagos, G. (2020). Breast cancer detection using convolutional neural networks. *arXiv preprint arXiv:2003.07911*.

[32] Agarap, A. F.M. (2018, febrero). Sobre la detección del cáncer de mama: una aplicación de algoritmos de aprendizaje automático en el conjunto de datos de diagnóstico de wisconsin. En *Proceedings of the 2nd international conference on machine learning and soft computing* (pp. 5-9).

[33] Alejandro Rodriguez-Ruiz, Kristina Lång, Albert Gubern-Merida, Mireille Broeders, Gisella Gennaro, Paola Clauser, Thomas H Helbich, Margarita Chevalier, Tao Tan, Thomas Mertelmeier, Matthew G Wallis, Ingvar Andersson, Sophia Zackrisson, Ritse M Mann, Ioannis Sechopoulos, Stand-Alone Artificial Intelligence for Breast Cancer Detection in Mammography: Comparison With 101 Radiologists, *JNCI: Journal of the National Cancer Institute*, Volume 111, Issue 9, Septiembre de 2019, páginas 916–922, <https://doi.org/10.1093/jnci/djy222>

[34] Al-Antari, M. A., Al-Masni, M. A., Choi, M. T., Han, S.M., Kim, T. S. (2018). A fully integrated computer-aided diagnosis system for digital X-ray mammograms through deep learning detection, segmentation, and classification. *International journal of medical informatics*, 117, 44-54.

[35] Al-Masni, M. A., Al-Antari, M. A., Park, J. M., Gi, G., Kim, T. Y., Rivera, P., ... Kim, T. S. (2018). Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO-based CAD system. *Computer methods and programs in biomedicine*, 157, 85-94.

[36] Nameirakpam Dhanachandra, Khumanthem Manglem, Yambem Jina Chanu, Image Segmentation Using K -means Clustering Algorithm and Subtractive Clustering Algorithm, *Procedia Computer Science*, Volume 54, 2015, Pages 764-771, ISSN 1877-0509, <https://doi.org/10.1016/j.procs.2015.08.111>

[37] Minaee, S., Boykov, Y. Y., Porikli, F., Plaza, A. J., Kehtarnavaz, N., Terzopoulos, D. (2021). Image Segmentation Using Deep Learning: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1–1. doi:10.1109/tpami.2021.3059968

[38] Lee, R., Gimenez, F., Hoogi, A. et al. A curated mammography data set for use in computer-aided detection and diagnosis research. *Sci Data* 4, 170177 (2017). <https://doi.org/10.1038/sdata.2017.177>

[39] MicroDicom - Free DICOM viewer and software.

[40] pydicom documentation — pydicom 2.3.0 documentation

[41] López Montiel, M., Rubio, Y., Sánchez-Adame, M., Orozco Rosas, U. (2019). Algoritmo de procesamiento de imágenes para señales de tránsito.

[42] Plotly Python Graphing Library <https://plotly.com/python/>

[43] Cómo configurar el aumento de datos de imagen en Keras (machinelearningmastery.com)

[44] `tf.keras.preprocessing.image.ImageDataGenerator` | TensorFlow v2.9.1

[45] `tf.keras.optimizers.Adam` | TensorFlow v2.9.1
