



# UNIVERSIDAD TÉCNICA PARTICULAR DE LOJA

*La Universidad Católica de Loja*

## ÁREA TÉCNICA

### INGENIERO EN SISTEMAS INFORMÁTICOS Y COMPUTACIÓN

TRABAJO DE TITULACIÓN

Redes neuronales convolucionales para mejorar la resolución  
de imágenes médicas

**Autor** : Sarango Vega, Jefferson Hernan

**Director (a)**: Jiménez Gaona, Yuliana del Cisne

LOJA - ECUADOR

2022



*Esta versión digital, ha sido acreditada bajo la licencia Creative Commons 4.0, CC BY-NY-SA: Reconocimiento-No comercial-Compartir igual; la cual permite copiar, distribuir y comunicar públicamente la obra, mientras se reconozca la autoría original, no se utilice con fines comerciales y se permiten obras derivadas, siempre que mantenga la misma licencia al ser divulgada. <http://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>*

2022

## Aprobación del director del trabajo de titulación

Loja, 21 de Enero del 2022

Magister.  
Fernanda Maricela Soto Guerrero  
**Coordinador(a) de Titulación**

Ciudad.-

De mi consideración:

El presente Trabajo de Titulación denominado Red neuronal convolucional para mejorar la resolución de imágenes médicas, realizado por Jefferson Hernan Sarango Vega, ha sido orientado y revisado durante su ejecución, por cuanto se aprueba la presentación del mismo. Así mismo, doy fe que dicho Trabajo de Titulación ha sido revisado por la herramienta antiplagio institucional.

Particular que comunico para los fines pertinentes.

Atentamente,

Firma del Director del Trabajo de Titulación  
Yuliana del Cisne Jiménez Gaona  
C.I.: 1103898019

### **Declaración de autoía y cesión de derechos**

“Yo, Jefferson Sarango, declaro y acepto en forma expresa lo siguiente:

- Ser autor del Trabajo de Titulación denominado: redes neuronales convolucionales para mejorar la resolución de imágenes médicas, de la Titulación de Ingeniería en Sistemas Informáticos y Computación, específicamente de los contenidos comprendidos en: Marco teórico, Capítulo 1. Metodología, Capítulo 2. Resultados y discusión, Capítulo 3, Conclusiones y Recomendaciones, siendo Yuliana del Cisne Jiménez Gaona, directora del presente trabajo; y, en tal virtud, eximo expresamente a la Universidad Técnica Particular de Loja y a sus representantes legales de posibles reclamos o acciones judiciales o administrativas, en relación a la propiedad intelectual. Además, ratifico que las ideas, conceptos, procedimientos y resultados vertidos en el presente trabajo investigativo son de mi exclusiva responsabilidad.
- Que mi obra, producto de mis actividades académicas y de investigación, forma parte del patrimonio de la Universidad Técnica Particular de Loja, de conformidad con el artículo 20, literal j), de la Ley Orgánica de Educación Superior; y, artículo 91 del Estatuto Orgánico de la UTP, que establece: “Forman parte del patrimonio de la Universidad la propiedad intelectual de investigaciones, trabajos científicos o técnicos y tesis de grado que se realicen a través, o con el apoyo financiero, académico o institucional (operativo) de la Universidad”.
- Autorizo a la Universidad Técnica Particular de Loja para que pueda hacer uso de mi obra con fines netamente académicos, ya sea de forma impresa, digital y/o electrónica o por cualquier medio conocido o por conocerse, sirviendo el presente instrumento como la fe de mi completo consentimiento; y, para que sea ingresada al Sistema Nacional de Información de la Educación Superior del Ecuador para su difusión pública, en cumplimiento del artículo 144 de la Ley Orgánica de Educación Superior.

Firma: .....

Autor: Jefferson Sarango

C.I.: 1105707341

### **Dedicatoria**

Quiero dedicar este trabajo de titulación a mi familia especialmente a mi madre Hilda Josefina Vega Sarango que ha sido mi apoyo incondicional en todas las etapas de mi vida, es mi ente motivador para lograr superarme cada día, ofreciendome siempre su amor y su confianza cuando nadie ha creído en mí, también a mi padre Hernan Sarango Lanche que gracias a su paciencia me ha inculcado las buenas costumbres haciendome saber que las cosas no llegan fácil siempre debemos trabajar por nuestros sueños gracias a esto he logrado cumplir mi sueño que es titularme como ingeniero.

También quiero dedicar este trabajo de titulación a mi hermano Jose Alfredo Sarango Vega que aunque hoy no se encuentra físicamente conmigo, él siempre fue una persona optimista me brindo su apoyo en las diferentes etapas de mi vida, sus consejos que me han sido de gran ayuda, así también agradezco a mi hermana Zonia del Cisne Sarango Vega que ha sido parte fundamental de mi formación como persona.

Finalmente quiero agradecer a todas las personas que de una u otra manera contribuyeron en la realización de este trabajo de investigación logrando culminar esta meta, siempre los llevare en mi corazón y en mis recuerdos.

## **Agradecimiento**

Al finalizar tan arduo trabajo de titulación quiero aprovechar este espacio justo y consecuente para agradecer a todas las personas que formaron parte de este proyecto y expresarles mis sinceros agradecimientos, a la Msc. Yuliana del Cisne Jiménez Gaona por admitirme para ser parte de este trabajo de titulación y realizarlo bajo su dirección, brindándome su orientación, apoyo y confianza durante el desarrollo del trabajo guiándome con sus valiosas ideas siempre enmarcadas en la ética, quiero agradecerle también por ayudarme con los medios para poder realizar este trabajo como accesos remoto a máquinas y base de datos que han sido recursos de gran ayuda para que este trabajo de titulación se desarrolle de la mejor manera.

También quiero hacer llegar un sincero agradecimiento al Ph.D. Pablo Vicente Torres Carrión y a la Ph.D. Ruth Reátegui, integrantes del tribunal del trabajo de titulación, ya que gracias a sus valiosas aportaciones y recomendaciones han permitido mejorar este trabajo de titulación. Agradezco a la Universidad Técnica Particular de Loja que por medio de sus docentes me brindaron sus conocimientos en las diferentes materias cursadas durante el transcurso de mi carrera, formándome de una manera íntegra que me permite llegar a ser un profesional en la carrera que elegí. Quiero agradecer a Dios a mi madre y a mi familia por el apoyo incondicional durante toda esta etapa de mi vida y ahora que finaliza les quiero agradecer por estar en todo momento de mi vida.

## Índice de Contenido

Carátula.....	I
Aprobación del director del trabajo de titulación .....	II
Declaración de autoía y cesión de derechos .....	III
Dedicatoria .....	V
Agradecimiento .....	VI
Índice de Contenido .....	VII
Resumen .....	1
Abstract .....	2
Introducción.....	3
Capítulo uno.....	5
Marco Teórico .....	5
1.1 Background .....	5
1.2 Problemática .....	8
1.3 Justificación.....	9
1.4 Objetivos .....	10
1.4.1 <i>Generales</i> .....	10
1.4.2 <i>Específicos</i> .....	10
Capítulo dos .....	11
Trabajos relacionados.....	11
2.1 Super resolución de imágenes usando Redes Neuronales Convolucionales .....	11
2.2 Super resolución en imágenes de mamografía .....	14
2.3 Residual Dense Network (RDN) .....	15
2.4 Enhanced Deep Residual Network (EDSR).....	15
Capítulo tres.....	17
METODOLOGÍA .....	17
3.1 Flujo de Trabajo .....	17
3.2 Base de Datos.....	17
3.3 Aumento de datos .....	18
3.4 Super resolución de imágenes mediante los algoritmo RDN y EDRS .....	19
3.4.1 <i>Algoritmo RDN</i> .....	19
3.4.2 <i>implmentación del algoritmo rdn</i> .....	20
3.4.3 <i>Algoritmo EDSR</i> .....	21
3.4.4 <i>Implementación del algoritmo EDRS</i> .....	21
3.5 Métricas de evaluación de la calidad de la imagen restaurada.....	22
3.5.1 <i>Peak signal noise ratio(psnr)</i> .....	22
3.5.2 <i>Structural similarity measure(ssim)</i> .....	24
Capítulo cuatro.....	26
Resultados y discusión .....	26
4.1 Aumento de Datos .....	26

4.2	Resultados de las métricas de evaluación PSNR y SSIM.....	26
4.3	Dispersión de los datos del algoritmo RDN. ....	30
4.4	Dispersión de los datos del algoritmo EDSR. ....	30
	Conclusiones.....	33
	Recomendaciones .....	34
	Glosario .....	35
	Referencias .....	36

### Índice de Tablas

Tabla 1	Técnicas de aumento de datos.....	18
Tabla 2	Hiperparámetros algoritmo RDN.....	20
Tabla 3	Hiperparámetros algoritmo EDRS.....	22
Tabla 4	Rango de valores metrica PSNR Y SSIM.....	23
Tabla 5	Valores metrica PSNR y SSIM.....	26
Tabla 7	Nuevas imágenes algoritmo RDN Y EDSR.....	28

### Índice de Figuras

Figura 1	Arquitectura SRCNN.....	12
Figura 2	Estadísticas de metrica PSNR.....	13
Figura 3	Comparación de los métodos utilizados.....	13
Figura 4	Arquitectura de una red neuronal.....	14
Figura 5	Flujo de Trabajo.....	17
Figura 6	Arquitectura global RDN.....	19
Figura 7	Funcionamiento del algoritmo EDSR.....	21
Figura 8	Funcionamiento de la metrica PSNR.....	24
Figura 9	Dispercion de los datos del algoritmo RDN.....	30
Figura 10	Dispercion de los datos del algoritmo EDSR.....	31

## Resumen

La mamografía es una de las técnicas más comúnmente usadas para la detección de cáncer de mama. Sin embargo, estas imágenes pueden presentar baja calidad en su resolución y contraste por el ruido que produce el equipo durante la toma de la imagen. El objetivo principal de este trabajo es mejorar la calidad y super-resolución de imágenes de mamografía mediante dos algoritmos basados en redes neuronales convolucionales. Para la metodología (i) se descarga la base de datos CBIS-DDSM, (ii) se extrae manualmente las regiones de interés (Rols). (iii) Se aumenta los datos (Rols), (iv) se mejora la super resolución de las Rols mediante los algoritmos EDSR and RDN. (v) Finalmente, se evalúa la calidad de las nuevas imágenes generadas mediante las métricas de evaluación PSNR y SSIM. Los resultados principales indican que el algoritmo RDN obtuvo una media de PSNR=32.68 dB y SSIM=0.82, y EDSR una media de PSNR=39.05 dB y SSIM=0.90 respectivamente. En conclusión, los resultados experimentales demuestran que el algoritmo EDSR produce imágenes más claras visiblemente con una calidad aceptable dentro del rango establecido (38dB a 40 dB).

*Palabras claves:* Redes neuronales convolucionales, mamografía, super resolución.

### **Abstract**

Mammography is one of the most commonly used techniques for detecting breast cancer. However, these images may present low quality in their resolution and contrast due to the noise produced by the equipment during the taking of the image. The main objective of this work is to improve the quality and super-resolution of mammography images through two algorithms based on convolutional neural networks. For the methodology (i) the CBIS-DDSM database is downloaded, (ii) the regions of interest (Rols) are manually extracted. (iii) The data (Rols) is increased, (iv) the super resolution of the Rols is improved by means of the EDSR and RDN algorithms. (v) Finally, the quality of the new images generated is evaluated using the PSNR and SSIM evaluation metrics. The main results indicate that the RDN algorithm obtained an average of PSNR=32.68 dB and SSIM=0.82, and EDSR an average of PSNR=39.05 dB and SSIM=0.90 respectively. In conclusion, the experimental results demonstrate that the EDSR algorithm produces visibly clearer images with acceptable quality within the established range (38dB to 40dB).

*Keywords:* Convolutional neural network, mammography, super resolution.

## Introducción

El cáncer de mama es una de las principales causas de muerte a nivel mundial, principalmente en mujeres. En el área de la oncología, la radiografía es la técnica más comúnmente usada para la detección de ciertas características propias de la neoplasia en mama (Ragab et al., 2019). Como resultado de estos análisis de rayos x varias imágenes médicas son almacenadas en diferentes formatos digitales, generando un crecimiento exponencial de datos, específicamente en el ámbito de la salud.

Actualmente, la mamografía es uno de los métodos de detección temprana más recomendados por la Sociedad Americana contra el Cáncer y el Colegio Americano de Radiología (Globocan, 2018). En vista de que es una técnica superior a otras modalidades, para detectar lesiones mamarias en un estado temprano. Además, proporciona un control eficiente y adquisición de imágenes digitales de la mama mientras expone al paciente a una mínima radiación (Meenalochini & Ramkumar, 2021)

Estos estudios de resonancia mamaria se pueden interpretar con un apartado de la última versión del sistema BIRADS, sin embargo el diagnóstico manual tradicional requiere una intensa carga de trabajo por parte de los patólogos expertos, quienes son propensos a errores de diagnóstico (Andersson et al., 2008; Timmers et al., 2012; Van Der Waal et al., 2015).

Por las razones descritas previamente, se utilizan diferentes algoritmos de inteligencia artificial (IA) para procesar esta información. Esta agrupación de arquitecturas, métodos y algoritmos construyen Sistemas computacionales asistidos (CAD) que sirven para detección y diagnóstico de cáncer. Un sistema CAD (Gardezi et al., 2019) es utilizado por el radiólogo como una segunda opinión, para brindar mayor seguridad en el diagnóstico de su paciente a partir de la imagen observada. Un sistema CAD consta de varias fases previas a la detección tumoral. 1. Pre-procesamiento de imágenes, 2. Segmentación, 3. Extracción-Selección de características y 4. Clasificación. Durante el pre-procesamiento se realiza (i) Eliminación de ruido, de artefactos y músculo pectoral, (ii) Mejorar la calidad de la imagen, el contraste y la super-resolución, y (iii) Aumento de datos.

En vista de que durante la toma de la imagen el equipo puede producir ruidos como gaussiano, sal y pimienta, speckle, moteado, etc, la disminución de contraste, artefactos, pérdida de información entre otras características que pueden influir en la baja resolución, calidad de una imagen y por ende en la baja precisión de resultados del CAD (Jiménez-gaona et al., 2020), este trabajo de tesis busca principalmente mejorar la calidad y super-

resolución de imágenes de mamografía mediante dos algoritmos de aprendizaje profundo basados en redes neuronales convolucionales, tales como Enhanced deep residual networks (EDSR) (Lim et al., 2017) y Residual Dense Block (RDN)(Abbass, 2020). Estos algoritmos se basan en arquitecturas comúnmente usadas en la literatura para super resolución, transferencia de aprendizaje y aprendizaje profundo como ResNet y Densenet, con la finalidad de brindar mayor precisión en la clasificación de anomalías presentes en la mama (Chen et al., 2018; Rybiątek & Jeleń, 2020). Además de ayudar a reducir radiaciones y biopsias innecesarias en el caso de mama densa o pequeñas microcalcificaciones que son difíciles de identificar a primera vista.

Estos algoritmos fueron evaluados mediante métricas de evaluación de calidad de la imagen para validar los algoritmos de SR una vez que las imágenes han sido restauradas. Las métricas más comúnmente usadas para evaluar los resultados de super-resolución son: PSNR (Peak signal to Noise Ratio) y SSIM(Structural Similarity Index)(Lu et al., 2010; Rajkumar & Malathi, 2016). Los resultados principales indican que el algoritmo EDSR obtuvo imágenes de mejor calidad visual con una media de PSNR=39.05 dB y SSIM=0.90 respectivamente, valores aceptables dentro de los rangos (38dB a 40 dB) establecidos en la literatura Rajkumar, S., & Malathi, G. (2016), Sheba, K. U., & Raj, S. G. (2016) y Gao, X., Lu, W., Tao, D., & Li, X. (2010).

Finalmente, los capítulos que conforman este documento son: capítulo 1, marco teórico donde constan conceptos esenciales para abordaje del presente trabajo; el capítulo 2, diseño metodológico, describe el proceso para mejorar la super resolución de imágenes de mamografía, el aumento de datos y la evaluación del rendimiento de los algoritmos basados en redes neuronales convolucionales; y el capítulo 3, discusión y análisis de resultados obtenidos en la evaluación, conclusiones y recomendaciones obtenidas del trabajo.

## Capítulo uno

### Marco Teórico

#### 1.1 Background

Hoy en día las imágenes digitales son una de las principales fuentes de recolección de información médica. Por lo que se han creado diferentes técnicas radiológicas para la detección de varias patologías tumorales, cerebrales ( MRI,CT ), mamarias (Ultrasonido, mamografía, PET ), pulmonares (Tomografía de Tórax), entre otras para ayudar al radiólogo a realizar un screening para la detección y diagnóstico temprano de una morbilidad en los pacientes.

Entre las técnicas de imagen más comunes para la adquisición de información médica mamaria, están Ultrasonido (US), Mamografía, Imagen de Resonancia Magnética (MRI), PET, CT, Histología y Tomosynthesis las cuales pueden ser complementados con biopsias, para la detección temprana de algún tipo de problema en la mama. En los siguientes párrafos se describe algunas de las técnicas más comunes:

La Mamografía hasta la actualidad es el método más utilizado para la detección de estadios iniciales de este tipo de cáncer, se realiza la toma de una imagen de mamografía mediante el uso de equipos que se los denomina como mamógrafos, estos equipos han avanzado en su desarrollo tecnológico desde los años sesenta, pasando de la mamografía análoga a la mamografía digitalizada, hasta llegar a la tecnología actual denominada mamografía digital (Andrés & Gómez, 2013), se hace el estudio de dos proyecciones de cada mama una craneo-caudal (CC) y otra medio lateral oblicua (MLO). La realización de dos proyecciones en cada mama es fundamental para no pasar por alto lesiones visualizadas en una sola proyección (Dra. Marina Álvarez Benito & Dra. María Cara García, 2015), entre las ventajas principales de realizarse una mamografía es que los niveles de radiación que recibe el cuerpo son muy bajos por lo que no altera la salud del paciente, es una técnica muy precisa porque nos ayuda a descubrir microcalcificaciones y lesiones que puede tener la mama.

El US mamario en 2D se usa principalmente en pacientes que tienen una alta posibilidad de tener cáncer o que por alguna circunstancia no puedan someterse a otro tipo de técnica en la que se haga uso de rayos X. En el transcurso del tiempo ha demostrado ser una técnica de imagen de excelencia en el momento de evaluar la glándula mamaria, esta técnica es un apoyo a la mastografía ya que ayuda a detectar lesiones adicionales como ganglios axilares, piel, músculo pectoral y tejidos densos (Ortiz de Iturbide María Cecilia, n.d.). Esta técnica es segura no invasiva y no utiliza radiación (Ultrasonido general 2018)

La MRI en 3D es una de las principales técnicas en diagnosticar cáncer de mama. La MRI puede detectar lesiones que no son visibles en otras modalidades de imagen y que resultan ser benignas es decir falso positivos tal como indica (Ziemssen et al. 2016) detectando de mejor manera las propiedades físicas y características del tejido mamario que no suelen detectarse mediante ecografía o US. La MRI no genera radiaciones en gran cantidad en el cuerpo del paciente que con el tiempo sean peligrosas.

Sin embargo, cuando el médico detecta alguna anomalía presente en la radiografía o imagen digital es necesario complementar el estudio con una biopsia. La biopsia es la principal fuente de diagnóstico para descartar o confirmar un cáncer de mama. Durante el proceso el médico especialista obtiene células del área donde se cree que está el problema para posteriormente proceder a realizar los estudios en un laboratorio (Insausti 2004), y así saber de manera acertada si existen algún tipo de células cancerosas.

Por otro lado, estas técnicas digitales requieren de un médico experto o radiólogo para realizar el análisis manual de las imágenes, lo que conlleva un largo periodo de tiempo, además de errores de diagnóstico. En base a ello, y con los avances de la inteligencia artificial (IA) se han venido desarrollando los sistemas CAD como una segunda opinión y asistencia a los radiólogos para diagnosticar y detectar una lesión, masa, nódulo, microcalcificación tumoral o no.

Los sistemas CAD en la actualidad sirven de ayuda al profesional de la salud para tomar una decisión más acertada en el diagnóstico. Los CAD tienen como información de entrada imágenes en formato digital para luego continuar con las fases que componen estos

sistemas: preprocesamiento, segmentación, extracción y selección de características, clasificación y análisis de resultados (Castelló 2016).

No obstante, los equipos médicos producen diferentes ruidos, artefactos y otros factores, que durante la recolección de imágenes causan que obtengamos un resultado de baja calidad, lo que puede ocasionar problemas para el procesamiento, clasificación e interpretación computacional de estas imágenes.

Es por ello que la visión por computador y los algoritmos de IA están siendo utilizados para procesar e interpretar esta información. Algoritmos principalmente enfocados en Machine Learning y Deep Learning por la precisión en los resultados presentados en diferentes investigaciones en donde los autores utilizaron principalmente redes neuronales convolucionales para la clasificación de lesiones mamográficas.

Por ejemplo el autor (Samik Real Enríquez 2019) propone tres redes convulsiones: 1. ResNet50, con dos capas de neuronas completamente conectadas de 512 neuronas y 4 neuronas respectivamente. 2. Una arquitectura de 4 capas convolucionales y 3 capas de neuronas completamente conectadas. La primera capa convolucional tiene 16 filtros, la segunda capa tiene 32 filtros, la tercera tiene 64 y la cuarta tiene 128 filtros. Todas estas capas usan filtros de tamaño 3x3 (Samik Real Enríquez 2019), y el 3. Modelo una arquitectura ResNet50, con dos capas de neuronas completamente conectadas de 512 neuronas y 4 neuronas respectivamente. Se utilizó un dropout de 0.5 entre las dos últimas capas. Los resultados obtenidos en cuanto a la exactitud de cada modelo fueron de 25%, 62% y 97.63% respectivamente.

Por otro lado el autor (Enzo Camargo Fernández Baca, 2016) propone evaluar el desempeño de 2 métodos de super resolución aplicado a imágenes médicas en 2D. Los métodos implementados se denominaron Iterative Back Projecting (IBP) e Iterative Kernel Steering (IKS), utilizando el indicador PSNR para evaluar la calidad la imagen original (HR) y la nueva imagen generada en Super Resolución (SR). Los resultados obtenidos de este trabajo indican que se logró mejorar la resolución de una imagen de hasta 3 veces (3x) de lo que fue la imagen original, si la imagen de entrada tiene una resolución de 240 x 240 píxeles,

se incrementa hasta en 720 x 720 pixeles, 3 veces en cada dirección ancho y alto (Enzo Camargo Fernández Baca, 2016).

En base a ello este trabajo de fin de titulación se enfoca en resolver un problema de pre-procesamiento denominado super resolución de imágenes o Single Image Super Resolution (SISR), cuyo objetivo principal es mejorar la calidad de las imágenes digitales de manera que se pueda obtener una mayor precisión en segmentación y clasificación de lesiones mamarias.

## 1.2 Problemática

En el Ecuador según datos del Instituto Nacional de Estadística y Censos (INEC) en 2019, el cáncer de mama ocupó el onceavo lugar como causa de muerte en mujeres, las estadísticas también muestran que se incrementó la tasa de mortalidad por esta causa de 3,9 en 2016 a 4,46 muertes por cada cien mil habitantes en el 2019.

Estas cifras hacen evidente la necesidad de detectar en estados tempranos la neoplasia (cáncer), el autoexamen ayuda mucho, pero en algunos casos se requiere de la mamografía para su detección, especialmente en ciertos tipos de cáncer en las que en sus primeras etapas no muestran síntomas, se constituye entonces en una esperanza para alterar el desarrollo de la enfermedad y depende de la capacidad de la mamografía para detectar cánceres ocultos y probablemente curables. Para ello la mamografía debe tener buena calidad y resolución de imagen, es decir dependerá en términos generales de las posibilidades técnicas del sistema mamográfico, de las dificultades anatómicas de la mama y de un experto profesional que la interprete.

Esta técnica de imagen permite reproducir en un plano bidimensional un órgano que en realidad tiene de dos o tres dimensiones, por lo cual las imágenes obtenidas constan de la superposición de múltiples planos, de tal manera que el profesional médico tenga las herramientas necesarias para emitir un diagnóstico temprano.

Los resultados de la mamografía requieren de un análisis del profesional médico especializado para emitir un diagnóstico al hacerse de forma manual tradicional demanda

de un trabajo pormenorizado, muchas de las veces exponiéndose a posibles errores, para evitar esto se pueden ayudar utilizando en el procesamiento de la información los sistemas computacionales asistidos (CAD) que usan para detectar y diagnosticar el cáncer.

El pre-procesamiento es una fase primordial en los sistemas CAD para obtener una buena precisión en la clasificación de anomalías benignas o malignas, a través de la eliminación de ruidos, mejorar el contraste, eliminar artefactos y recuperar las principales características que pueden incidir en la baja resolución de una imagen y en la precisión de resultados del CAD (Villalobos-castaldi & Contreras, 2017).

Por lo tanto, mejorar la resolución de las imágenes durante el pre-procesamiento, juega un papel fundamental para la clasificación de lesiones esto ayudaría a reducir radiaciones y biopsias innecesarias en el caso de mama densa o pequeñas microcalcificaciones que son difíciles de identificar a primera vista, lo que conlleva a mejorar la precisión de resultados en las fases consecuentes. En base a ello planteamos la siguiente hipótesis ¿Se puede mejorar la calidad y la resolución de las imágenes de mamografía, mediante la aplicación de algoritmos de redes neuronales convolucionales?, ¿Cuál de los dos algoritmos comparados presenta mejores resultados en términos de PSNR y SSIM

### **1.3 Justificación**

Durante la toma de la imagen el equipo puede producir ruidos (gaussiano, sal y pimienta, poisson), disminución de contraste, artefactos, pérdida de información entre otras características que pueden influir en la baja resolución de una imagen y en la precisión de resultados. Al mejorar la calidad y resolución de las imágenes estas proveen de información confiable para la clasificación de lesiones mamarias.

Por lo antes mencionado, el presente trabajo de investigación es importante para contribuir con una de las fases principales que involucra a los pasos posteriores de un sistema CAD. El preprocesamiento de imágenes dentro del campo Biomédico, es un problema importante ya que ayuda a una detección temprana del cáncer de mama mediante el uso de imágenes de mamografía. A partir de este preprocesamiento y mejora de la calidad de imágenes se genera un set de datos libre de ruido que posteriormente contribuirá en una

mejor precisión de la segmentación y clasificación de lesiones, masas, tumores, microcalcificaciones en la mama o cualquier anomalía presente en la mama.

En vista de que un CAD constituye una segunda opinión para localizar y diagnosticar tumores que no presentan sintomatología, mejoran la calidad y la resolución del examen mamográfico, beneficia a los médicos especialistas para diagnosticar y detectar tumores malignos en la mama al disponer de imágenes claras que disminuyan notablemente los errores que pueden presentarse por la baja claridad de la imagen.

Por ende, una buena resolución de la imagen mamográfica evita que él o la paciente deban ser sometidos a una biopsia o al mismo examen varias veces, aunque en la mamografía los niveles de radiación a los que se expone equivalen a la dosis que recibe una persona en unos meses por radiación natural, es más beneficioso contar con imágenes óptimas que permitan distinguir con claridad cualquier bulto que esté formándose para poder tratarlo a tiempo.

## **1.4 Objetivos**

### **1.4.1 Generales**

Mejorar la calidad y resolución de imágenes de mamografía, mediante redes neuronales convolucionales

### **1.4.2 Específicos**

- Diseñar e implementar dos redes neuronales convolucionales para mejorar la resolución de imágenes de mamografía.
- Comparar la calidad de la imagen restaurada mediante métricas de precisión como psnr y ssim

## Capítulo dos

### TRABAJOS RELACIONADOS

En este capítulo se describen algunas ideas principales de distintos trabajos publicados en revistas indexadas, los cuales han sido analizados de una manera minuciosa para llevar a cabo esta investigación y realizar una comparación entre dos Redes Neuronales Convolucionales para el mejoramiento de imágenes médicas de mamografía. Se expondrán las ideas fundamentales y los resultados más relevantes de cada uno de los artículos científicos que han servido con un sustento científico al momento de desarrollar este trabajo de titulación.

#### 2.1 Super resolución de imágenes usando Redes Neuronales Convolucionales

La aplicación de las redes neuronales convolucionales han demostrado tener resultados prometedores para lograr imágenes de SR, con una estructura simple de tres capas de convolución. Las redes convolucionales utilizan kernels, con los que realizan la operación de convolución sobre la imagen para detectar características como, por ejemplo, bordes y texturas (Puertas et al. 2018).

Tal como indica Dong et al., 2016 en su artículo Image Super-Resolution Using Deep Convolutional Networks en donde proponen un método de aprendizaje profundo para mejorar la resolución de una imagen, aplicando una red neuronal convolucional para mapear de un extremo a otro las imágenes de baja y alta resolución. Una de las primeras actividades es escalar el tamaño de la imagen utilizando la técnica de interpolación bicúbica, que se aplica únicamente en el preprocesamiento de la imagen, realizando algunas operaciones como:

- I. Extracción y representación de parches.
- II. Mapeo no lineal.
- III. reconstrucción.


A partir de estos pasos previos se prosigue con una fase de entrenamiento de la red en donde los algoritmos de Deep Learning demuestran mayor eficacia en cuanto a su

entrenamiento, usando una gran cantidad de datos. En esta investigación se utilizó la base de datos ImageNet con un total de 395,909 imágenes. Para evitar el problema de sobreajuste de la red, se aplicó rotaciones y traslaciones logrando aumentar las imágenes originales y generando imágenes sintéticas. Finalmente, Dong et al. utilizó las métricas PSNR y SSIM para evaluar la calidad de restauración de la imagen con tres escalas 2,3, 4 cuyo mayor valor se dio en la escala 2 con un índice de PSNR= 32,45 y SSIM=0.90.

Por otro lado, la red SRCNN (Dong et al. 2016) recrea operaciones convencionales como la extracción-representación, mapeo no lineal y reconstrucción para crear un conjunto de características de la imagen cuyo número es igual al número de operadores o filtros. El mapeo no lineal consiste en hacer un mapeo a cada vector y cada vector mapeado se lo representa como un parche de alta resolución. En la etapa de reconstrucción se obtiene la imagen final de alta resolución ver figura 1.

**Figura 1**

*Imagen Arquitectura SRCNN*



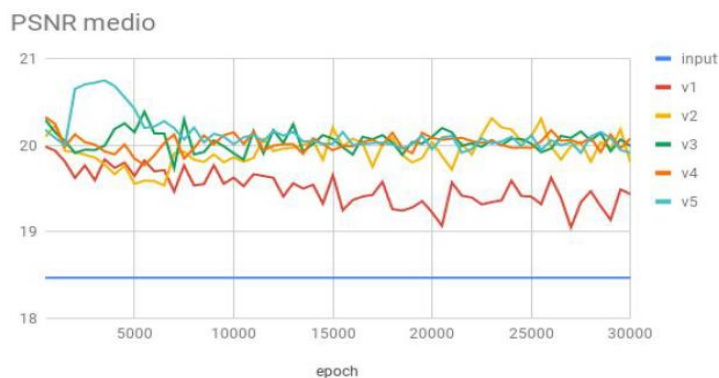
*Nota.* Arquitectura SRCNN(Dong et al., 2016)

Dong et al. utilizó una colección de datos de imágenes multispectrales, aumentando su número con el fin de mejorar los resultados de entrenamiento. Finalmente, experimentó con 5 variaciones con el fin de explorar de una manera detallada cuál variación tiene más potencial ver figura 3. El entrenamiento de la red se lo limitó a 30.000 épocas por limitaciones

computacionales (Puertas et al. 2018). Todos estos experimentos permitieron evaluar cómo se incrementa el rendimiento de la red con las variantes que se aplicó, observando mejoras en cada una de ellas ver figura 2.

**Figura 2**

*Imagen estadísticas de métrica psnr*




*Nota.* PSNR medio sobre el conjunto de test(Dong et al., 2016)

Finalmente, el método SRCNN fue comparado con otros métodos de super resolución tales como SC (sparse coding-based method), NE+LLE (eighbour embedding + locally linear embedding method), ANR(Anchored Neighbourhood Regression method), A+(Adjusted Anchored Neighbourhood Regression method) KK(sparse regression method) a continuación en la figura 3 se muestra los valores obtenidos de la comparación de los métodos dándole como valor más alto el método SRCNN que propone el autor .

**Figura 3**

*Imagen comparación de los métodos utilizados*




*Nota.* Comparación de los métodos (Dong et al., 2016)

En el trabajo de Abbass 2020, se aplicaron Redes Neuronales Convolucionales (CNN), para obtener una imagen de super resolución( SR), teniendo como datos de entrada una imagen de baja resolución ( LR) de la base de datos DIV2K. Esta base de datos contiene 800 imágenes de entrenamiento, 100 de prueba y 100 de validación.

En este trabajo también se realizó aumento de datos para el entrenamiento de la red, mediante técnicas básicas como rotaciones en diferentes ángulos, e inclinaciones buscando una mejor precisión en los resultados. Además, menciona que una red convolucional SRCNN proporciona un mejor rendimiento aplicando convolución traspuesta y una arquitectura más profunda, ver figura 4.

**Figura 4**

*Imagen de la red neuronal esta consta de cuatro fases: extracción de características, red densa residual, fusión de características y la red de reconstrucción.4*



*Nota.* Red neuronal convolucional propuesta por (Abbas 2020).

La red propuesta se implementa en Python con Tensorflow y se ejecuta en una GPU NVIDIA GeForce GTX 1660Ti. Los valores calculados de PSNR y SSIM para evaluar las imágenes de SR., indican que a mayor valor de PSNR (dB) mejor calidad de la imagen (Abbas 2020), para el algoritmo propuesto en esta investigación (SRCNN) el valor de la métrica PSNR en escala de x2 es de 36.66, en la escala de x3 es de 32.75 y en la escala de x4 es de 30.48 que estos valores están dentro de los rangos aceptables de dicha métrica de evaluación. Aplicando la métrica de evaluación SSIM para el mismo algoritmo, la escala de x2 es de 0.9542, para la escala de x3 0.8210 y finalmente para la escala de x4 es de 0.71 que están entre los valores aceptables de la métrica de evaluación.

## 2.2 Super resolución en imágenes de mamografía

La super resolución de imágenes médicas parte de un conjunto de imágenes de baja resolución LR, que mediante técnicas o algoritmos de machine learning o deep learning

permiten mejorar su calidad generando imágenes de alta resolución HR. Entre las técnicas que se a utilizado para lograr super resolución en imágenes de mamografía son la interpolación, el filtrado de paso de banda, el enmascaramiento de enfoque, algoritmos iterativos y redes neuronales convolucionales (Zheng, 2010), estos últimos están generando una mayor precision en cuanto a la resolución de imágenes médicas.

Las redes neuronales convolucionales (CNN) han sido aplicadas en las imágenes de mamografía en distintas tareas como la de localización y detección de lesiones, evaluación de riesgos, recuperación de imágenes clasificación y super resolución. Ayudando a los radiólogos a brindar un diagnóstico más preciso de las lesiones basado en un análisis cuantitativo (Abdelhafiz et al. 2019).

Otro tipo de redes neuronal son las Antagonic Generative Networks (GAN) que básicamente tiene un Generador y el Discriminador que permiten realizar procesamiento de imágenes de mamografías asi como mejorar la super resolución de imagenes mantiendo las características extraídas (Guo et al. 2015) Además, su función de pérdida es robusta para ayudar a que la red se entrene de manera estable y, al mismo tiempo, alivia el problema de suavizado excesivo de la imagen reconstruida causado por la función de pérdida MSE(Guo et al. 2015).

### **2.3 Residual Dense Network (RDN)**

El algoritmo RDN es una red basada en la arquitectura DenseNet y se lo aplica en la obtención de imágenes SR (Super Resolucion). En DenseNet, las capas de transición se colocan en dos bloques densos adyacentes. Mientras que en RDN, las capas densas conectadas se combinan con la fusión de características locales (LFF) mediante el uso del aprendizaje residual local (Zhang et al. 2018) ver figura 6.

### **2.4 Enhanced Deep Residual Network (EDSR)**

El algoritmo EDSR es una red basada en la arquitectura Resnet que tiene un desempeño excelente en problemas de visión por computadora (Lim et al. 2017), además se optimiza analizando y eliminando módulos incensarios para simplificar la arquitectura de la red esto nos da como beneficio que no se use demasiada memoria de la GPU, este

modelo de referencia sin la capa de normalización por lotes ahorra aproximadamente un 40% del uso de memoria durante el entrenamiento. En consecuencia, podemos construir un modelo más grande que tenga un mejor rendimiento con recursos computacionales limitados (Lim et al. 2017) ver figura 7.

## Capítulo tres

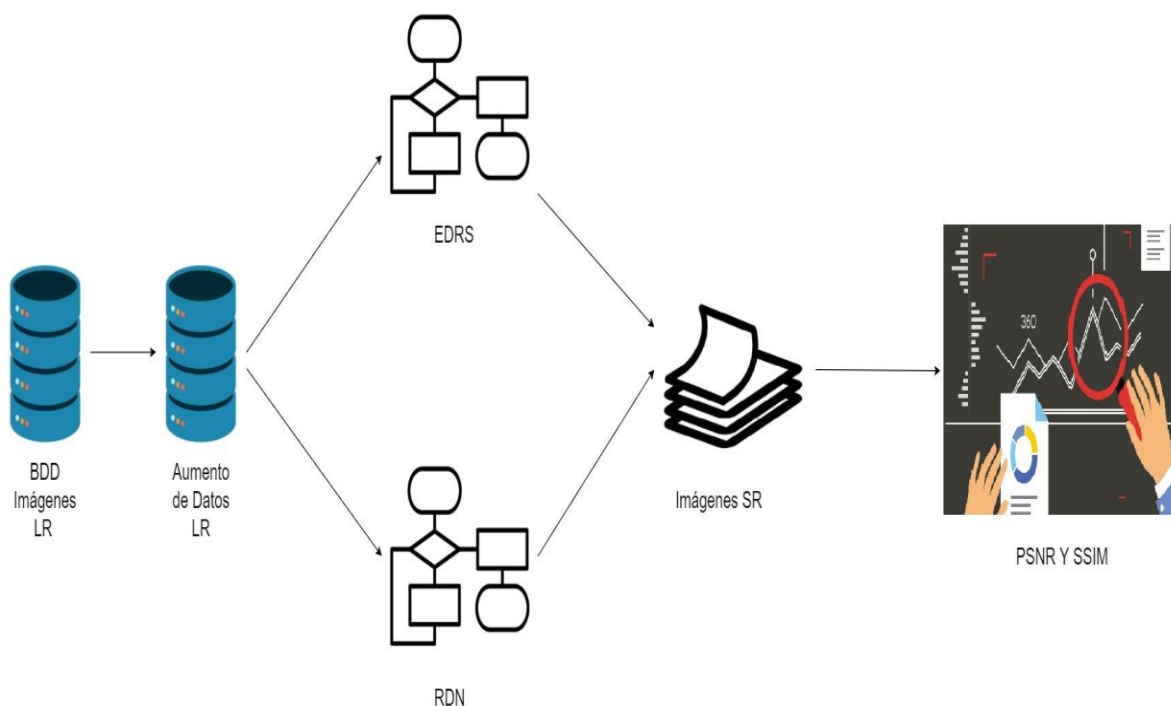
### METODOLOGÍA

#### 3.1 Flujo de Trabajo

El esquema de trabajo establecido en esta investigación se describe a continuación en la figura5.

**Figura 5**

*Imagen que describe el flujo de trabajo*



*Nota.* Flujo de trabajo propuesto por el autor

#### 3.2 Base de Datos

La base de datos de mamografía utilizada fue CBIS-DDSM (Curated Breast Imaging Subset – Digital Database for Screening Mammography) (Yaffe, 2001), con un total de 637 imágenes. Las imágenes CBIS-DDSM contienen proyecciones Cráneo Caudal (CC) y Media Lateral Oblicua (MLO) de cada mama. El formato de las imágenes médicas son DICOM, con dimensiones aproximada de 3784 x 5912 píxeles, cuyo tamaño fue reducido a 128 x 128 con la intención de mejorar el rendimiento computacional al momento de procesar dichas imágenes. El conjunto de imágenes que se han utilizado son 636, con 475 imágenes benignas y 161 malignas, (Smith, 2020).

### 3.3 Aumento de datos

El entrenamiento de redes neuronales convolucionales requiere de un gran set de datos, con el fin de capturar las características esenciales de las imágenes y lograr un rendimiento completo, evitando además el sobreajuste de la red.

Para el aumento de los datos primeramente se realizó la extracción manual de la Región de Interés (Rol) mediante el software ImageJ (Sánchez, 2014), para obtener las máscaras binarias de cada una de las imágenes y realizar el entrenamiento de los modelos de la red. Además, se utilizó la técnica de cross-validation para dividir el total de datos que se obtuvo aplicando las técnicas de aumento de datos que fue un total de 5095 imágenes en 80% de entrenamiento que nos da un total de 4076 imágenes y 20% de prueba que corresponde a 1019 imágenes.

Para el proceso de aumento de Rols se utilizó varias técnicas tradicionales descritas en la tabla 1:

**Tabla 1**

*Técnicas de aumento de datos*

Técnica	Descripción	Valores Utilizados
<b>Blur</b>	Desenfoca la imagen en la cantidad especificada	blur_1.5
<b>Fliph</b>	Voltear horizontalmente la imagen	fliph
<b>Flipv</b>	Voltear verticalmente la imagen	flipv
<b>Rot90</b>	Girar la imagen en la cantidad especificada	rot_90
<b>Rot180</b>	Girar la imagen en la cantidad especificada	rot_180
<b>Trans</b>	Desplaza los píxeles de la imagen en las cantidades especificadas en las direcciones x y	trans_20_20

*Nota.* Esta tabla se observa las técnicas y los valores aplicados para el aumento de datos en esta investigación


### 3.4 Super resolución de imágenes mediante los algoritmo RDN y EDRS

#### 3.4.1 Algoritmo RDN

Este algoritmo consta principalmente de cuatro partes: red de extracción de características superficiales (SFENet), bloques densos residuales ( RDB ), fusión de características densas ( DFF ) y, finalmente, la red de muestreo ascendente ( UPNet)(Zhang et al. 2018) como podemos apreciar en la figura 6.

**Figura 6**

*Imagen arquitectura global RDN*



*Nota.* Arquitectura RDN (Zhang et al., 2018).

Como se observa en la arquitectura se utilizan dos capas convolucionales (Conv) para extraer entidades poco profundas. La primera capa Conv extrae las características  $F_{-1}$  de la entrada LR:

$$F_{-1} = H_{SFE1}(I_{LR})$$

Ecuación 1

Este  $F_{-1}$  se utiliza luego para una mayor extracción de características superficiales y aprendizaje residual global. Luego, se aplica la segunda capa conv.  $F_0$ :

$$F_0 = H_{SFE2}(F_{-1})$$

Ecuación 2

Este  $F_0$ , la segunda capa de extracción de características poco profunda, se utiliza como entrada para los bloques densos residuales. Suponiendo que tenemos  $D$  bloques densos residuales, la salida  $F_d$  del  $d$ -ésimo RDB se puede obtener mediante donde  $H_{RDB}$ ,  $d$  denota las operaciones del  $d$ -ésimo RDB.

$$F_d = H_{RDB,d}(F_{d-1}) = H_{RDB,d}(H_{RDB,d-1}(\dots(H_{RDB,1}(F_0))\dots))$$

Ecuación 3

DFF fusiona características que incluyen fusión de características globales (GFF) y aprendizaje residual global (GRL). DFF hace un uso completo de las características de todas las capas anteriores y se puede representar como:

$$F_{DF} = H_{DFF}(F_{-1}, F_0, F_1, \dots, F_D)$$

Ecuación 4

FDF son los mapas de características de salida de DFF utilizando una función compuesta HFFF ESPCN se usa aquí en UPNet(Zhang et al. 2018).

$$I_{SR} = H_{RDN}(I_{LR})$$

Ecuación 5

### 3.4.2 implementación del algoritmo RDN

En la implementación del algoritmo RDN se utilizaron los parámetros descritos en la tabla 2. El tamaño de las capas convolucionales se ajustó a 3\*3 , y para la capa de extracción de características a 1\*1. Así mismo, el número de características que extrae de cada Rol es de 64, y el número de épocas de entrenamiento es de 30 (ver tabla 2) . Luego del aumento de los datos se obtuvo un total de 5095 imágenes divididas mediante la técnica de cross-validation en dos grupos el 80% para entrenamiento (4076) y el 20% para test (1019).

**Tabla 2**

*Hiperparámetros algoritmo RDN*

Hiperparámetros	Valores
<b>Numero de épocas</b>	30
<b>Tamaño del lote</b>	50
<b>Número de Bloques</b>	16
<b>Número de capas</b>	8
<b>Tamaño del parche</b>	10
<b>Escala</b>	4


*Nota.* Valores de los hiperparámetros de entrenamiento de la red RDN

### 3.4.3 Algoritmo EDSR

El algoritmo EDRS está basado en la arquitectura ResNet, y se lo ha utilizado para la clasificación y detección de objetos. EDSR puede apilar más capas de red para extraer más funciones, esto da un mejor rendimiento. EDSR optimiza el modelo de red con la función de pérdida del estilo de la norma L1, entrenando el modelo. Luego usa los parámetros obtenidos por los múltiples pequeños del modelo de entrenamiento para inicializar el modelo de muestreo de alta altitud, lo que puede reducir el tiempo de entrenamiento del modelo de muestreo en los altos dígitos (Lim et al. 2017), la arquitectura de este algoritmo se muestra a continuación en la figura 7.

**Figura 7**

*Imagen del funcionamiento del algoritmo EDSR*



*Nota.* Arquitectura EDSR (Lim et al., 2017).

En esta arquitectura podemos observar que se quitaron las capas de normalización por lotes de la red, en cada bloque residual, se colocan capas de escala constante después de las últimas capas de convolución. En la fase de prueba, esta capa se puede integrar en la capa de convolución anterior para la eficiencia computacional. No hay capas de activación de ReLU fuera de los bloques residuales (Lim et al. 2017), por lo que aumentar la cantidad de mapas de características hace que el entrenamiento sea inestable.

### 3.4.4 Implementación del algoritmo EDRS

En la implementación del algoritmo EDRS se utilizaron los parámetros descritos en la tabla 3. El total de imágenes utilizadas luego del aumento de datos es de 5095, este set

de datos fué dividido en dos grupos aplicando la técnica de cross-validation es decir el 80% para entrenamiento (4076 imágenes) y el 20% (1019 imágenes ) para test.

**Tabla 3**

*Hiperparámetros algoritmo EDRS*

Hiperparámetros	Valores
<b>ResBlocks</b>	32
<b>Numero de filtros</b>	256
<b>Número de Bloques</b>	50
<b>Número de épocas</b>	20
<b>Escala</b>	3

*Nota.* Valores de los hiperparámetros de entrenamiento de la red EDSR

### 3.5 Métricas de evaluación de la calidad de la imagen restaurada.

#### 3.5.1 *Peak signal noise ratio(psnr)*

Existen diferentes índices para evaluar la calidad de restauración de la imagen, por ejemplo PSNR, permite evaluar cuantitativamente la calidad de una nueva imagen. Este índice es responsable de medir la distorsión de las imágenes a partir de la diferencia en píxeles, y su valor se acerca al infinito cuando el MSE se acerca a cero. Esto muestra que un valor de PSNR (dB) más alto proporciona una calidad de imagen más alta. En el otro extremo de la escala, un valor pequeño del PSNR implica grandes diferencias numéricas entre imágenes (Tabla 4).

**Tabla 4**

Rango de valores de las métricas PSNR y SSIM

Calidad	PSNR(dB)	SSIM
<b>Baja</b>	<30	<0.90
<b>Aceptable</b>	38 - 40	0.95 - 0.90
<b>Alta</b>	40 - 50	0.95 - 1

*Nota.* Rango de valores en decibeles de **PSNR y SSIM**

Esta métrica es muy utilizada para medir la calidad de reconstrucción que ha tenido una imagen o video, su forma más simple de expresar como el cociente entre la energía máxima que puede alcanzar la señal y el ruido presente en ella(García et al. 2017) la ecuación 6 describe esta métrica de evaluación .

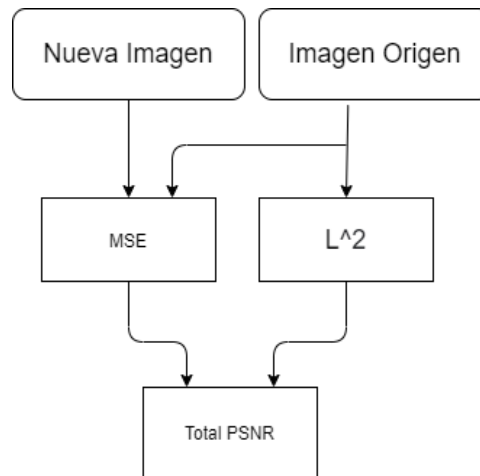
$$PSNR = 10 \cdot \log_{10} \left( \frac{L^2}{MSE} \right)$$

Ecuación 6

Donde, L es el valor máximo que puede tener una señal de la imagen, mientras que MSE es el error cuadrático medio. Este hace la comparación de las dos imágenes, como primer parámetro la imagen original y como segundo parámetro la nueva imagen generada por nuestro algoritmo, a continuación se explica en la figura 8 el funcionamiento de la métrica.

**Figura 8**

*Imagen del funcionamiento de la métrica PSNR*



*Nota.* Esquema de trabajo de la métrica PSNR

### 3.5.2 Structural similarity measure(ssim)

Esta métrica es muy utilizada en la literatura para evaluar la calidad de una imagen o de un video. Se encarga de medir la similitud de las imágenes a partir del brillo, contraste y estructura. Su valor es 1 si las imágenes comparadas son iguales y se vuelve más pequeño si difieren. Parte de la idea fundamental de que las señales de imagen están muy estructuradas, lo que significa que los píxeles dependen en gran medida unos de otros, sobre todo los que se encuentran próximos en la imagen (García et al. 2017), básicamente esta métrica mide la distorsión que ha sufrido la imagen en su estructura. El rango de valores SSIM para determinar la calidad de la nueva imagen se describen en la tabla 4.

La medida de distorsión estructural se complementa con la distorsión que la imagen sufre en luminancia y en contraste, utilizando para ello la media de valores en el entorno vecindad de un píxel como estimador de luminancia, y la desviación típica en el mismo entorno como estimador de contraste (García et al. 2017), la ecuación 7 describe esta métrica de evaluación.

$$SSIM(i, j) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}$$

Ecuación 7

Esta ecuación compara la similitud estructural de dos imágenes que en esta fórmula esta representada por  $i,j$  en donde  $\mu_x$  representa el promedio de  $x$  y  $\mu_y$  el promedio de  $y$ . Mientras tanto que  $\sigma_x^2$  es la varianza de  $x$ ,  $\sigma_y^2$  la varianza de  $y$ ,  $\sigma_{xy}$  la covarianza de  $x$ .  $C_1$  es igual  $(k_1L)^2$  y  $C_2$  es igual  $(k_2L)^2$  esto permite estabilizar la división con el denominador mas débil es decir evita desviaciones para cero.  $L$  es el rango dinámico de los pixeles mientras que  $k_1 = 0.01$  y  $k_2 = 0.03$  son valores dados por defecto.

## Capítulo cuatro

### RESULTADOS Y DISCUSIÓN

En este capítulo se presenta un detalle de los resultados obtenidos de la implementación y evaluación de los algoritmos basados en CNN, evaluados mediante las métricas descritas anteriormente.

#### 4.1 Aumento de Datos

La investigación inició con un total de 637 imágenes de mamografías, las cuales fueron procesadas por técnicas tradicionales de aumento de datos como rotación, traslado, entre otras descritas en la tabla 1. Como resultado de estas técnicas de aumento de datos se obtuvo un total de 5095 regiones de interés (Rols), las cuales sirvieron como datos de entrenamiento y prueba de los dos modelos convolucionales RDN (formato de la imagen de entrada .jpg) y EDSR (formato de la imagen de entrada .png).

#### 4.2 Resultados de las métricas de evaluación PSNR y SSIM

Los resultados de PSNR y SSIM más revelantes a partir de la implementación de los algoritmos de super resolución de imágenes se muestran en las Tabla 5.

**Tabla 5**

*Valores de las métricas PSNR/SSIM en ambos algoritmos de super resolución.*

ID	SR-RDN		ID	EDSR	
	PSNR(dB)	SSIM		PSNR (dB)	SSIM
DDSM_043_blur1	40.76	0.97	DDSM_043_blur1	46.41	0.97
DDSM_0607	40.46	0.95	DDSM_0381_blur1	46.23	0.97
DDSM_0120	40.33	0.95	DDSM_0275_blur1	45.95	0.97
DDSM_0468	40.22	0.94	DDSM_0228_blur1	45.76	0.97
DDSM_0466	40.20	0.96	DDSM_0120	45.63	0.91
DDSM_0168_blur1	40.18	0.94	DDSM_0467	45.57	0.97
DDSM_0188	40.14	0.94	DDSM_0466	45.51	0.97
DDSM_0275_blur1	40.14	0.97	DDSM_0212_blur1	45.38	0.97

<b>DDSM_0369</b>	40.05	0.95	<b>DDSM_079_blur1</b>	45.35	0.95
<b>DDSM_0538</b>	39.98	0.90	<b>DDSM_0368</b>	45.2	0.92
<b>DDSM_0212_blur1</b>	35.87	0.98	<b>DDSM_021_blur1</b>	39.5	1.0
<b>DDSM_0228_blur1</b>	37.00	0.97	<b>DDSM_0295_blur1</b>	38.17	1.0
<b>DDSM_0275_blur1</b>	40.14	0.97	<b>DDSM_0106_blur1</b>	41.14	0.97
<b>DDSM_043_blur1</b>	40.76	0.97	<b>DDSM_0212_blur1</b>	45.38	0.97
<b>DDSM_0189_blur1</b>	35.12	0.96	<b>DDSM_0228_blur1</b>	45.76	0.97
<b>DDSM_0256_blur1</b>	37.91	0.96	<b>DDSM_0275_blur1</b>	45.95	0.97
<b>DDSM_0381_blur1</b>	39.11	0.96	<b>DDSM_0381_blur1</b>	46.23	0.97
<b>DDSM_0466</b>	40.20	0.96	<b>DDSM_043_blur1</b>	46.41	0.97
<b>DDSM_0467</b>	39.95	0.96	<b>DDSM_0466</b>	45.51	0.97
<b>DDSM_0549</b>	38.83	0.96	<b>DDSM_0467</b>	45.57	0.97
<b>Media Aritmética</b>	32.68	0.82	<b>Media Aritmética</b>	39.05	0.90

*Nota.* Resumen de la selección imágenes con mejores valores en la métrica PSNR

En la tabla 5 podemos observar la media de los diez mejores resultados obtenidos por ambos algoritmos, tomando como referencia la métrica PSNR y SSIM. El valor promedio que obtuvo el algoritmo RDN es de 32.68 dB con un índice más alto de PSNR=40.76 dB en la imagen DDSM\_043\_blur1. Para la métrica SSIM se obtuvo un valor medio de 0.98 para la imagen DDSM\_0212\_blur1, esto demuestra que la calidad de la imagen no presenta errores visualmente (ver tabla 7). Sin embargo, la media de la métrica SSIM= 0.82 indica que no existe alta correlación entre las imágenes según la tabla 4.






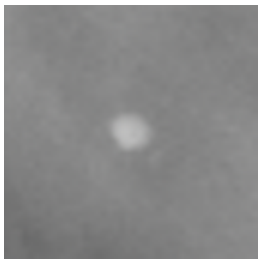
Por otro lado, el algoritmo EDSR obtuvo una métrica más alta de PSNR=46.41 sobre la imagen DDSM\_043\_blur1 con una media aritmética de PSNR=39.05, cuyos valores nos permite afirmar que este algoritmo generó imágenes de mejor calidad visual (ver tabla 7)







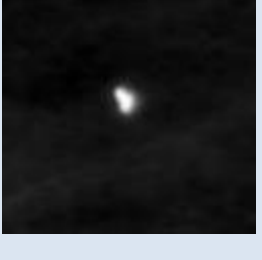
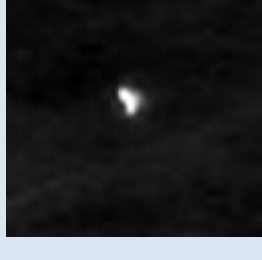
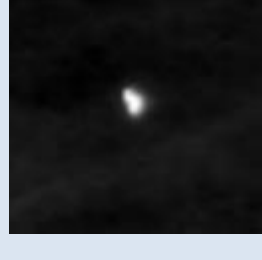
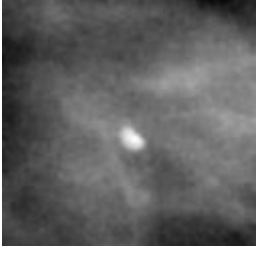
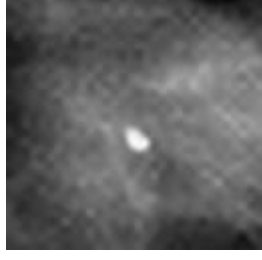
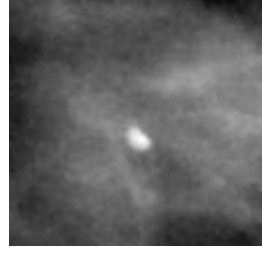

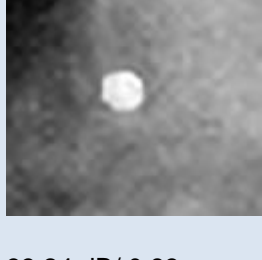

dentro del rango aceptable de decibeles según los autores Rajkumar, S., & Malathi, G. (2016), Sheba, K. U., & Raj, S. G. (2016) y Gao, X., Lu, W., Tao, D., & Li, X. (2010), ver tabla 4.

Para la métrica SSIM la imagen DDSM\_021\_blur1 obtuvo un valor de 1 lo que significa que la calidad de la imagen no presenta errores visualmente. La media de esta métrica en EDSR es de 0.90, lo que indica que a pesar de que existen diferencias con la imagen original esta se encuentra dentro de los valores aceptables. Esto se debe principalmente a que el modelo EDSR reconstruye con éxito las texturas y los bordes detallados en las imágenes (Rols) de mamografía y exhibe resultados de mejor calidad, en comparación con otros trabajos.

**Tabla 6**

*Comparación visual entre las imágenes originales (Rols) y las generadas por ambos algoritmos.*

ID	Rol original	SR-RDN	SR-EDSR
		PSNR/SSIM	PSNR/SSIM
DDSM_043_blur1		 40.76 dB/ 0.97	 46.41dB/ 0.97
DDSM_0607		 40.46 dB/ 0.95	 44.66 dB/ 0.96

DDSM_0212__blur1		 35.87 dB/ 0.98	 45.38 dB/ 0.97
DDSM_0228__blur1		 37.00 dB/ 0.97	 45.76 dB/ 0.97
DDSM_0381__blur1		 39.11 dB/ 0.96	 46.23 dB/ 0.97
DDSM_021__blur1		 35.00 dB/ 0.86	 39.50 dB/ 1.0
DDSM_0295__blur1		 33.24 dB/ 0.83	 38.17 dB/ 1.0


*Nota.* Resultados visuales de la métricas seleccionadas para ambos algoritmos RDN y EDSR.

### 4.3 Dispersión de los datos del algoritmo RDN.

La figura 9a muestra los resultados estadísticos obtenidos del algoritmo RDN en ambas métricas, datos generados mediante el software RStudio versión 1.4.17 usando el paquete ggplot2 para la visualización de datos. Para la métrica PSNR, los datos evidencian que la mayoría de puntuaciones oscilan entre 30 a 40 dB, valores que se encuentran en el rango aceptable para la calidad visual de reconstrucción que ha tenido la imagen. Mientras que la Figura 9b, muestra la dispersión de datos en la métrica SSIM, cuyos datos se concentran en el intervalo entre 0.80 y 0.95 también considerados aceptables según (Rajkumar & Malathi, 2016)

**Figura 9**

*9a. Indica la dispersión de los datos del algoritmo RDN para la métrica PSNR. 9b Indica la dispersión de los datos del algoritmo RDN para la métrica SSIM.*



*Nota.* Dispersión de Datos Métrica PSNR y SSIM para el algoritmo RDN.

### 4.4 Dispersión de los datos del algoritmo EDSR.


La figura 10a muestra los resultados de dispersión de datos obtenida del algoritmo EDSR para ambas métricas. Para la métrica PSNR, los datos demuestran que sus puntuaciones oscilan entre 30 a 45 dB, valores que indican un mejor índice en comparación

con el algoritmo RDN, que así mismo se consideran aceptables dentro del rango con respecto a la calidad de reconstrucción que ha tenido la imagen. En la figura 10b para la métrica SSIM, se muestra que la mayoría de los datos están ubicados en el intervalo entre 0.8 y 1 que son valores que indican una correlación alta entre la imagen original y la nueva imagen generada.

### Figura 10a y 10b

10a. Indica la dispersión de los datos del algoritmo EDSR con la métrica PSNR. 10b

Indica la dispersión de los datos del algoritmo ESDR con la métrica SSIM.



*Nota.* Dispersión de Datos Métrica PSNR y SSIM para el algoritmo EDRS.

Las métricas demuestran que los mejores resultados los presentó el algoritmo EDSR con una métrica PSNR promedio de 46.41dB y SSIM de 1, es decir que la calidad de la imagen no presenta errores visuales con respecto a la original y el algoritmo logro cumplir su propósito de mejorar la calidad visual de las imágenes. Finalmente, podemos afirmar que los algoritmos propuestos tuvieron un buen funcionamiento.

Estos resultados los podemos contrastar con el trabajo relacionado (Enzo Camargo Fernández Baca, 2016) sobre la “Evaluación del desempeño de dos métodos de súper resolución aplicado a imágenes médicas en 2D” en el cual se aplican dos métodos de super

resolución para una sola imagen (i) Kernel Steering(IKS) y para varias imágenes (ii) Iterative Back Projecting(IBP). Cuyas métricas se enfocan en solucionar el problema por cada pixel o región de pixeles y no en la imagen en sí. Los autores obtuvieron como resultados una media PSNR de 27.84 dB para el algoritmo IKS y una media PSNR de 30.19 dB para IBP. Estos valores reflejan una menor resolución en la nueva imagen en comparación con las obtenidas en nuestro trabajo.

Otro trabajo relacionado que aplica las dos métricas de evaluación PSNR y SSIM es (Anis, 2021) para evaluar la “Súper resolución de imágenes médicas usando CNN”. Aquí se aplicaron tres algoritmos para la SR de imágenes naturales: (i) EDSR, (ii) WDSR y (iii) SRGAN, los cuales se evalúan con y sin transferencia de aprendizaje. Los resultados obtenidos de estos algoritmos son PSNR = 40.38/ 39.02/ 38.15 y SSIM = 0.964/0.963/ 0.953 respectivamente. Siendo un indicativo de que los valores obtenidos en nuestro trabajo aceptables.

Por lo tanto, podemos concluir que con la aplicación de técnicas de aprendizaje profundo y transfer learning, específicamente con la aplicación de redes neuronales convolucionales se logra una mejor calidad visual y nitidez de las imágenes, esto lo demuestran los índices cuantitativos, cuyos valores se encuentran dentro de los rangos de decibeles establecidos como aceptables para imágenes médicas.

## Conclusiones

De este trabajo podemos concluir que por la falta de acceso a datos médicos surge la necesidad de aplicar técnicas de aumento de datos, las cuales son necesarias para el entrenamiento de redes neuronales convolucionales y evitar el problema de sobreajuste durante el entrenamiento de la red, permitiéndonos a posterior lograr una mayor precisión en los resultados de clasificación de lesiones benignas o malignas a partir de los algoritmos convolucionales.

Como resultado de la implementación y comparación de estos dos algoritmos convolucionales, se determinó que el algoritmo EDSR permite obtener una mejor calidad visual y super resolución de imágenes, medido por los índices presentados en las métricas PSNR y SSIM, cuyos valores se muestran entre los rangos aceptables según la literatura. Lo cual indica que las nuevas imágenes generadas con mejor calidad visual permitirán con mayor certeza realizar segmentación, clasificación y diagnóstico tumoral, así como un mejor rendimiento y precisión en los algoritmos de aprendizaje profundo.

Finalmente, proponemos como trabajos futuros agregar otras bases de datos públicas de mama a partir de rayos x como Inbreast, Mini -MIAS, Irma, así como otros tipos de técnicas radiológicas como Ultrasonido, PET para realizar un mejor entrenamiento de las redes. Así mismo proponemos implementar otro tipo de redes como las redes generativas (GAN), Autoencoders o Recurrentes para realizar aumento de datos y mejorar la super resolución de imágenes. Ofreciendo un análisis comparativo entre estos métodos para conocer sus ventajas para el procesamiento de imágenes, y asegurar una mejor clasificación de anomalías y diagnóstico temprano dentro de un sistema computacional CAD, evitando así una alta tasa de mortalidad a causa de este tipo de cáncer.

### **Recomendaciones**

Se recomienda que se sigan formando al preprofesional Utepelino con el desarrollo de este tipo de trabajos de titulación enfocados a los sistemas computacionales de diagnóstico, con la finalidad de ayudar a la comunidad y a los médicos expertos en la detección temprana de patologías, evitando así diagnósticos erróneos y biopsias innecesarias al paciente.

Brindar las competencias necesarias a los estudiantes de Ciencias de la computación para el análisis de datos y procesamiento de imágenes mediante técnicas de inteligencia artificial y algoritmos de aprendizaje profundo. Así como capacitarlos en el uso de recursos computacionales y máquinas virtuales en la nube para que puedan manejar de mejor manera la limitación que tenemos con los recursos computacionales.

## Glosario

**AUC:** Area under curve  
**CAD:** Computer aided system  
**CC:** Cranio caudal  
**CNN:** Convolutional neural network  
**DDSM:** Digital Database for Screening Mammography  
**DL:** Deep Learning  
**DM:** Digital Mammography  
**DNN:** Deep Neural Network  
**E2E:** End to End  
**EDSR:** Enhanced Deep Residual Network  
**ESPCN:** Efficient sub-pixel convolutional neural network  
**ESRGAN:** Enhanced Super-Resolution Generative Adversarial Networks  
**FN:** False Negative  
**FP:** False Positive  
**GAN:** Generative adversarial network  
**HR:** High resolution  
**IoU:** Intersection over Union  
**LR:** Low Resolution  
**MDSR:** Multi-scale Deep Super-resolution  
**MLO:** Mediolateral Oblique  
**PSNR:** Peak Signal to Noise Ratio  
**RDB:** Residual Dense Block  
**RDN:** Residual Dense Network  
**ReLU:** Rectified Linear Unit  
**RNN:** Recurrent Neural Network  
**RoI:** Region of interest  
**SegNet:** Segmentation Network  
**SISR:** Single Image Super Resolution  
**SR-GAN:** Super-Resolution Using a Generative Adversarial Network  
**SSIM:** Structural Similarity Index Metric  
**TN:** True Negative  
**TP:** True positive  
**VGG:** Visual Geometric Group  
**VDSR:** Very Deep Network for SR

## Referencias

- Abbass, M. Y. (2020). Residual Dense Convolutional Neural Network for Image Super-Resolution. *Optik*, 165341. <https://doi.org/10.1016/j.ijleo.2020.165341>
- Andersson, I., Ikeda, D. M., Zackrisson, S., Ruschin, M., Svahn, T., Timberg, P., & Tingberg, A. (2008). Breast tomosynthesis and digital mammography: a comparison of breast cancer visibility and BIRADS classification in a population of cancers with subtle mammographic findings. *European Radiology*, 18(12), 2817–2825. <https://doi.org/10.1007/S00330-008-1076-9>
- Andrés, C., & Gómez, O. (2013). Imágenes diagnósticas en patología mamaria Diagnostic imaging in breast pathology. *Oncología Medicina & Laboratorio*, 19, 11–12.
- Anis, M. (2021). *Super-Resolution of Medical Images using CNN*. <http://repository.cuilahore.edu.pk/xmlui/handle/123456789/3009>
- Chen, Y., Zhang, Q., Wu, Y., Liu, B., Wang, M., & Lin, Y. (2018). Fine-Tuning ResNet for Breast Cancer Classification from Mammography. *Undefined*, 536, 83–96. [https://doi.org/10.1007/978-981-13-6837-0\\_7](https://doi.org/10.1007/978-981-13-6837-0_7)
- Dong, C., Loy, C. C., He, K., & Tang, X. (2016). Image Super-Resolution Using Deep Convolutional Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(2), 295–307. <https://doi.org/10.1109/TPAMI.2015.2439281>
- Dra. Marina Álvarez Benito, & Dra. María Cara García. (2015). *RADIOLOGÍA BÁSICA DE LA MAMA Capítulo 1. Introducción al diagnóstico por imagen de la mama CAPÍTULO 1. INTRODUCCIÓN AL DIAGNÓSTICO POR LA IMAGEN DE LA MAMA AUTORES*. 1–21.
- Enzo Camargo Fernández Baca. (2016). *EVALUACIÓN DEL DESEMPEÑO DE 2 MÉTODOS DE SÚPER RESOLUCIÓN APLICADO A IMÁGENES MÉDIC [UNIVERSIDAD NACIONAL DE INGENIERIA]*. [http://cybertesis.uni.edu.pe/bitstream/uni/5389/1/camargo\\_fe.pdf](http://cybertesis.uni.edu.pe/bitstream/uni/5389/1/camargo_fe.pdf)
- Gardezi, S. J. S., Elazab, A., Lei, B., & Wang, T. (2019). Breast Cancer Detection and Diagnosis Using Mammographic Data: Systematic Review. *Journal of Medical Internet Research*, 21(7). <https://doi.org/10.2196/14464>
- Globocan. (2018). Global Cancer Facts & Figures 4th Edition. *American Cancer Society*, 4, 1–76. <https://www.cancer.org/content/dam/cancer-org/research/cancer-facts-and-statistics/global-cancer-facts-and-figures/global-cancer-facts-and-figures-4th-edition.pdf>
- Jiménez-gaona, Y., Rodríguez-álvarez, M. J., & Lakshminarayanan, V. (2020). Deep-Learning-Based Computer-Aided Systems for Breast Cancer Imaging: A Critical Review. *Applied Sciences 2020, Vol. 10, Page 8298, 10(22)*, 8298. <https://doi.org/10.3390/APP10228298>
- Lim, B., Son, S., Kim, H., Nah, S., & Lee, K. M. (2017). *Enhanced Deep Residual*

*Networks for Single Image Super-Resolution.*

- Lu, W., Liu, W., Gao, X., & Li, X. (2010). *Image quality assessment and human visual system*. <https://doi.org/10.1117/12.862431>
- Meenalochini, G., & Ramkumar, S. (2021). Survey of machine learning algorithms for breast cancer detection using mammogram images. *Materials Today: Proceedings*, 37(Part 2), 2738–2743. <https://doi.org/10.1016/J.MATPR.2020.08.543>
- Ortiz de Iturbide María Cecilia, C. O. A. (n.d.). *Actualidades en la detección oportuna de cáncer mamario: mastografía y ultrasonido*. Retrieved January 4, 2021, from [www.medigraphic.org.mx](http://www.medigraphic.org.mx)
- Ragab, D. A., Sharkas, M., Marshall, S., & Ren, J. (2019). Breast cancer detection using deep convolutional neural networks and support vector machines. *PeerJ*, 2019(1), e6201. <https://doi.org/10.7717/PEERJ.6201/TABLE-8>
- Rajkumar, S., & Malathi, G. (2016). A Comparative Analysis on Image Quality Assessment for Real Time Satellite Images. *Indian Journal of Science and Technology*, 9(34), 1–11. <https://doi.org/10.17485/IJST/2016/V9I34/96766>
- Rybiatek, A., & Jeleń, Ł. (2020). Application of DenseNets for Classification of Breast Cancer Mammograms. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12133 LNCS, 266–277. [https://doi.org/10.1007/978-3-030-47679-3\\_23](https://doi.org/10.1007/978-3-030-47679-3_23)
- Sánchez, D. (2014). *Análisis del software ImageJ para el análisis científico de imágenes*. E.T.S.I y Sistemas de Telecomunicación (UPM).
- Smith, K. (2020). *CBIS-DDSM*. The Cancer Imaging Archive (TCIA): Maintaining and Operating a Public Information Repository.
- Timmers, J. M. H., Van Doorne-Nagtegaal, H. J., Zonderland, H. M., Van Tinteren, H., Visser, O., Verbeek, A. L. M., Den Heeten, G. J., & Broeders, M. J. M. (2012). The Breast Imaging Reporting and Data System (BI-RADS) in the Dutch breast cancer screening programme: its role as an assessment and stratification tool. *European Radiology*, 22(8), 1717–1723. <https://doi.org/10.1007/S00330-012-2409-2>
- Van Der Waal, D., Den Heeten, G. J., Pijnappel, R. M., Schuur, K. H., Timmers, J. M. H., Verbeek, A. L. M., & Broeders, M. J. M. (2015). Comparing Visually Assessed BI-RADS Breast Density and Automated Volumetric Breast Density Software: A Cross-Sectional Study in a Breast Cancer Screening Setting. *PLOS ONE*, 10(9), e0136667. <https://doi.org/10.1371/JOURNAL.PONE.0136667>
- Villalobos-castaldi, F. M., & Contreras, O. (2017). *Red Neuronal Convolutacional para la segmentación de imágenes placentarias*. *DI*, 10–12.
- Yaffe, M. J. (Martin J. (2001). *IWDM 2000: 5th International Workshop on Digital Mammography: proceedings of the workshop, June 11-14, 2000, Toronto, Canada*. 838. <http://www.eng.usf.edu/cvprg/Mammography/Database.html>
- Zhang, Y., Tian, Y., Kong, Y., Zhong, B., & Fu, Y. (2018). *Residual Dense Network*

*for Image Super-Resolution. 0–10.*