

DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

**“Análisis Digital de Imágenes para la Detección
de Anomalías en mama”**

POR

Ing. Arianna Victoria Salas Chávez

TESIS

**PRESENTADA COMO REQUISITO PARCIAL PARA OBTENER EL
GRADO DE MAESTRO EN CIENCIAS EN INGENIERÍA ELÉCTRICA**

DIRECTOR DE TESIS

M. C. Martín Gerardo Vázquez Rueda

ISSN: 0188-9060



RIITEC: (13)-TMCIE-2016

Torreón, Coahuila, México
Noviembre 2016

Torreón, Coah. **15/Noviembre/2016**
Dependencia: DEPI/CPCIE
Oficio: DEPI/CPCIE/205/2016
Asunto: Autorización de impresión de tesis.

C. Arianna Victoria Salas Chavez
CANDIDATO AL GRADO DE MAESTRO EN CIENCIAS EN INGENIERÍA ELÉCTRICA.
PRESENTE

Después de haber sometido a revisión su trabajo de tesis titulado:

"Análisis Digital de Imagen para la Detección de Anomalía en Mama"

Habiendo cumplido con todas las indicaciones que el jurado revisor de tesis hizo, se le comunica que se le concede la autorización con número de registro **RIITEC: (13)-TMCIE-2016**, para que proceda a la impresión del mismo.

ATENTAMENTE
EDUCACIÓN TECNOLÓGICA FUENTE DE INNOVACIÓN

M.I.J. ARMANDO LONGORIA DE LA TORRE
Jefe de la División de Estudios de Posgrado e Investigación
del Instituto Tecnológico de la Laguna

SECRETARÍA DE
EDUCACIÓN PÚBLICA
de la Laguna
División de Estudios de Posgrado
e Investigación



Torreón, Coah., 15/Noviembre/2016

M.I. ARMANDO LONGORIA DE LA TORRE
JEFE DE LA DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

Por medio de la presente, hacemos de su conocimiento que después de haber sometido a revisión el trabajo de tesis titulado:

"Análisis Digital de Imagen para la Detección de Anomalía en Mama"


Desarrollado por el **C. Arianna Victoria Salas Chavez**, con número de control **M1413027** y habiendo cumplido con todas las correcciones que se le indicaron, estamos de acuerdo que se le conceda la autorización de la fecha de examen de grado para que proceda a la impresión de la misma.

ATENTAMENTE
EDUCACIÓN TECNOLÓGICA FUENTE DE INNOVACIÓN

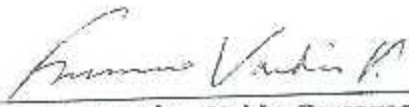

M.C. Martín Vázquez Rueda
Asesora/Directora de Tesis



M.C. Sergio F. Salas Huerta
Comité Tutorial



Dr. Francisco Flores García
Comité Tutorial



Dr. Francisco Valdes Perezgasga
Comité Tutorial

Índice

Índice de Figuras.....	iii
Índice de Tablas.....	v
Agradecimientos.....	vi
Dedicatoria.....	viii
Resumen.....	ix
Abstract.....	x
1 Introducción.....	1
1.1 Planteamiento del problema.....	3
1.2 Objetivos de la investigación.....	3
1.2.1 Objetivo general.....	3
1.2.2 Objetivos específicos.....	3
1.3 Formulación de Hipótesis.....	4
1.4 Justificación.....	4
1.5 Antecedentes.....	5
1.5.1 Análisis del Cáncer de Seno usando técnicas de procesamiento de imagen.....	5
1.5.2 Detección de Cáncer de seno en mamografías usando funciones de procesamiento de imagen.....	7
1.5.3 Identificación de Masas Anormales en imágenes digitales de mamografías.....	9
2 Mamografías, Diagnóstico y Calcificación.....	11
2.1 Mamografías y su diagnóstico.....	11
2.1.1 Cambios de tejido mamario observables en una mamografía.....	11
2.1.2 Categorización de Mamografías.....	12
2.1.3 Léxico Mamográfico.....	13
3 Procesamiento de imágenes digitales.....	19
3.1 Representación Digital simple.....	19
3.2 Imágenes en escala de grises.....	20
3.3 Filtros digitales.....	21
3.3.1 Filtros en dominio del espacio.....	21
4 Inteligencia Artificial.....	25
4.1 Lógica Difusa.....	25
4.2 Redes Neuronales Artificiales.....	26
4.2.1 Ventajas de las Redes Neuronales Artificiales.....	27



4.2.2	Aprendizaje Supervisado.....	28
4.2.3	Perceptrón Simple.....	31
4.2.4	Backpropagation.....	33
5	Desarrollo del proyecto.....	38
5.1	Pruebas preliminares.....	39
5.2	Visual Studio Community.....	41
5.2.1	Lenguaje C#.....	42
5.2.2	Formularios Windows Form y aplicaciones clientes inteligentes.....	43
5.2.3	Descripción General.....	44
5.2.4	Codificación den C#.....	51
6	Resultados y Conclusiones.....	65
7	Fuentes de información.....	68



Índice de Figuras.

Fig. 1.1 Diagrama de análisis de distribución para detección de cáncer en mamografía.....	5
Fig. 1.2 Diagrama de procesamiento de imagen para detectar microcalcificaciones.....	6
Fig. 1.3 Imágenes resultantes del procesamiento de imagen digital, a) Imagen Original, b) Imagen con detección de bordes, c) Imagen con relleno de espacios vacíos, d) Imagen resultante final [2].....	6
Fig. 1.4 Imagen original detección de cáncer con funciones de Matlab [3].....	7
Fig. 1.5 Estructura tipo diamante [3].....	7
Fig. 1.6 Diagrama de procesamiento de imagen para la detección de masas [3].....	8
Fig. 1.7 Diagrama para mejorar la imagen [4].....	9
Fig. 1.8 Formación de bloques homogéneos 2X2 [4].....	9
Fig. 2.1 Planos referenciados a mama derecha [8].....	13
Fig. 2.2 Morfología de masa [8].....	13
Fig. 2.3 Margen [8].....	14
Fig. 2.4 Densidad de masa [10].....	14
Fig. 2.5 Nódulos, categorías BI_RADS [9].....	14
Fig. 2.6 Nódulos, Clasificación BI-RADS [9].....	15
Fig. 2.7 Mama Categoría BI-RADS 0 [11].....	16
Fig. 2.8 Mama Categoría BI-RADS 1 [10].....	16
Fig. 2.9 Mama Categoría BI-RADS 3 [10].....	17
Fig. 2.10 Mama Categoría BI-RADS 4 [10].....	17
Fig. 2.11 Mama Categoría BI-RADS 5 [10].....	18
Fig. 2.12 Mama Categoría BI-RADS 6 [10].....	18
Fig. 3.1 Representación matricial de una imagen.....	23
Fig. 3.2 Representación matricial de una imagen con filtro mediana.....	23
Fig. 4.1 Ejemplo de una red neuronal artificial [17].....	27
Fig. 4.2 Esquema de una Neurona Artificial.....	28
Fig. 4.3 Modelo Perceptrón Simple con n entradas y m salidas.....	31
Fig. 4.4 Estructura Backpropagation.....	33
Fig. 5.1 Bosquejo del proyecto.....	38
Fig. 5.2 Imagen original a tratar.....	39
Fig. 5.3 Imagen con diferentes brillos.....	39
Fig. 5.4 Imagen con diferentes contrastes y filtros no lineales.....	40
Fig. 5.5 Imagen a color.....	40
Fig. 5.6 Imágenes en blanco y negro con diferentes umbrales.....	40
Fig. 5.7 Imagen binaria con diferentes umbrales.....	41
Fig. 5.8 Bordes definidos de la imagen binaria.....	41
Fig. 5.9 Ventana principal de la aplicación.....	45
Fig. 5.10 Apertura de imagen de referencia y de estudio en los diferentes formatos.....	45
Fig. 5.11 Bonotes de giro de acomodo de imagen e indicadores de resolución de las imágenes.....	46
Fig. 5.12 Pantalla anterior con imágenes cargadas en diferentes orientaciones.....	46
Fig. 5.13 Imágenes orientadas correctamente.....	47
Fig. 5.14 Apartado Datos del paciente.....	47
Fig. 5.15 Sección de Datos Adicionales.....	48



Fig. 5.16 Sección de control de imagen.....	48
Fig. 5.17 Resultante del Procesamiento de imagen.....	49
Fig. 5.18 Resultado del Diagnóstico del paciente.....	50
Fig. 5.19 Menú de Inicio, opción de Guardar y Salir de la aplicación.....	50
Fig. 5.20 Librerías a utilizar.....	51
Fig. 5.21 Abrir imagen tipo DICOM.....	51
Fig. 5.22 Código para la apertura de otro tipo de imagen.....	52
Fig. 5.23 Convertir imágenes a escala de grises.....	52
Fig. 5.24 Modificar brillo de las imágenes.....	52
Fig. 5.25 Aplicación de filtro Mediana.....	53
Fig. 5.26 Código para obtener las imágenes binarias.....	53
Fig. 5.27 Diagrama de flujo para calcular la densidad máxima promedio de la imagen.....	54
Fig. 5.28 Cierre de las imágenes.....	54
Fig. 5.29 Código para obtener las diferencias entre las imágenes.....	54
Fig. 5.30 Código para la detección de Bordes.....	55
Fig. 5.31 Código para determinar el índice de redondez de cada área encontrada.....	55
Fig. 5.32 Código para identificar el plano correspondiente.....	55
Fig. 5.33 Diagrama de flujo para determinar la densidad promedio del área.....	56
Fig. 5.34 Código para el cálculo del tamaño del área.....	56
Fig. 5.35 Diagrama de la red neuronal artificial utilizada.....	57
Fig. 5.36 Variable de entrada de la RNA.....	58
Fig. 5.37 Matriz de pesos entre la capa de entrada y la capa intermedia.....	58
Fig. 5.38 Matriz de pesos entre la capa oculta y la capa de salida.....	58
Fig. 5.39 Matriz de bias entre la capa de entrada y la capa intermedia, vector de bias para la capa de salida.....	59
Fig. 5.40 Entrada y salidas de cada capa de la RNA.....	59
Fig. 5.41 Método para determinar la salida de la RNA.....	59
Fig. 5.42 Esquema de conexión de la RNA para la categorización de BIRADS.....	60
Fig. 5.43 Entradas de la RNA para la categorización BIRADS.....	61
Fig. 5.44 Salidas de la RNA y entrada de la misma.....	61
Fig. 5.45 Matriz de pesos entre la capa de entrada y la capa intermedia.....	61
Fig. 5.46 Matriz de pesos entre la capa intermedia y la salida.....	62
Fig. 5.47 Matriz de bias entre la capa oculta y la intermedia y vector de bias de la capa de salida.....	62
Fig. 5.48 Método para determinar la salida de la red.....	62
Fig. 5.49 Selección de Radio-Button.....	63
Fig. 5.50 Código para guardar el diagnóstico.....	63
Fig. 5.51 Imagen resultante de la opción guardar.....	64
Fig. 6.1 Imagen muestra utilizada para realizar el entrenamiento de las Redes Neuronales Artificiales.....	66



Índice de Tablas.

Tabla 1 Distribución porcentual de morbilidad hospitalaria de la población de 20 años y más, por tumores malignos según sexo.....	1
Tabla 2. Formatos de imagen en bits [12].....	19
Tabla 3 Funciones de transferencias y sus gráficas.....	29
Tabla 4 Funciones de Transferencia.....	30
Tabla 5 Tabla de resultados para la identificación de anomalía.....	58
Tabla 6 Tabla de resultados para la categorización BIRADS.....	61
Tabla 7 Tabla de resultados de pruebas.....	65



Agradecimientos.

Agradezco a Dios por ser mi fuente de serenidad y paz durante este proceso.

Le doy gracias a mis padres Blanca Chávez y Sergio Salas por darme siempre la oportunidad de crecer. Enseñarme que la meta que me proponga la puedo lograr y que el trabajo duro es el camino para lograrlo. Les doy las gracias por inculcarme los valores que me hacen la persona que soy; por enseñarme lo que es la responsabilidad, respeto a mis decisiones y valores además de lo que se significa el trabajo duro. Mamá te doy las gracias por siempre ponerme el ejemplo y demostrarme que puedo realizar todo lo que me proponga, haciéndome una mujer fuerte, inteligente y dispuesta a seguir creciendo. Papá te doy las gracias por presentarme el amor a la ingeniería, sembrar en mí la espinita de la duda y las ganas de siempre querer saber más e inculcarme el no temor a hacer las cosas, por hacerme fuerte y decidida. A ambos les agradezco infinitamente su amor incondicional y apoyo sobre todas las cosas, por siempre impulsarme a realizarme y darme todas las herramientas para lograrlo, por ser un ejemplo de perseverancia y lucha que me acompañarán en toda mi vida.

A mi esposo Homero Muñoz le doy las gracias por ser mi porrista número uno, por siempre darme los ánimos para seguir adelante, además de hacer todo lo posible por brindarme un ambiente sano y sin preocupaciones para que yo pudiese trabajar en el proyecto sin preocupaciones. Por siempre celebrar cada paso adelante en el proyecto y apoyarme cuando daba un paso hacia atrás. Agradezco por compartir el amor al saber más y siempre interesarse en mis logros. Le agradezco por compartir mi felicidad y por siempre demostrarme su amor, cariño, apoyo en mis decisiones y lealtad en todo el camino, además de querer siempre ayudarme.

A mi bebé, que a pesar de estar en espera aún, me ha dado la alegría y amor más grande durante este proceso. Espero y un día esté muy orgulloso de su mamá y pueda brindarle todas las enseñanzas y valores que me han dado mi familia y este proceso y así brindarle un futuro prometedor.



Agradezco a mi hermano Sergio Salas, mi cuñada Sofía Zapata, y mi sobrinito Sergio Salas Zapata por siempre estar pendiente de mi progreso y apoyarme, por ser parte importante de mi vida y ver por la unión familiar en todo momento. A mi hermano Sergio Salas, te agradezco por ser un ejemplo de dedicación profesional y sembrar en mi la inquietud de una carrera en ingeniería, que después se convertiría en inquietud por una Maestría.

A mis amigos por siempre echar porras y mostrar interés por mi evolución en el proyecto, agradezco por soportar negativas a reuniones sociales y soportar un poco mi abandono; siempre consientes del motivo y apoyando mi desarrollo profesional. Celebrar cada logro por mínimo que fuera.

Doy gracias a mis maestros durante toda mi formación pero en especial doy gracias al M.C. Martín Gerardo Vázquez Rueda, por depositar la confianza en mí y darme la oportunidad de desarrollar una tesis profesional. Respetar mis métodos y decisiones, al igual que brindarme conocimientos para el desarrollo de este proyecto. Por darme la oportunidad de crecer profesionalmente y adquirir nuevos conocimientos.

Agradezco al Consejo de Ciencia y Tecnología (CONACYT) y al Instituto Tecnológico de La Laguna por el apoyo educacional y económico para la realización del proyecto de tesis "Análisis digital de imágenes para la detección de anomalías en mama".



Dedicatoria.

A mis padres:

Que este trabajo sea el reflejo de su dedicación como padres, maestros, y amigos. Espero que este proyecto los haga sentir orgullosos tanto de mí como de ustedes, porque gracias a sus enseñanzas, sus valores inculcados, su ejemplo de responsabilidad y compromiso, además de su ejemplo de perseverancia y constancia, me ha sido posible crecer como ser humano y como profesionalista. Gracias a su amor y respeto a mis decisiones es que son posibles mis logros. Dedico mi trabajo a mis 2 pilares de fortaleza y amor. Los amo.

A mi esposo:

Por ser mi acompañante y mis fuerzas en momentos difíciles, por darme el ejemplo de la unión en pareja, y por demostrarme su amor y apoyo incondicional que nos prometimos. Gracias por su motivación, por ser mi soporte y aceptar mi estrés, además de darme ánimos y siempre decirme que yo era capaz de lograrlo. Gracias a él por hacerse cargo en ciertos momentos, sin su apoyo, dedicación y amor hubiera sido muy difícil lograrlo. Te amo.

A mi bebé:

Porque a partir del momento de su existencia, me dio otro tipo de alegría y un motivo más por hacer las cosas con un buen propósito, me ha dado más inspiración para seguir creciendo y ser un buen ejemplo para él y darle el futuro que merece, así como también darle las herramientas para que seas un buen ser humano. Te amo.

A mis familiares:

Les dedico mi esfuerzo y dedicación en agradecimiento por su apoyo incondicional, sus ánimos en todo momento y su interés contante en mi crecimiento. Gracias por darme el ejemplo de la unión familiar y el compromiso hacia los miembros de la familia.

A mis amigos:

Por su apoyo en todo momento, por tratar de siempre levantarme el ánimo y liberarme del estrés. Gracias por su interés y estar pendientes en cada logro realizado.



Resumen

El documento describe el proceso llevado a cabo para la elaboración de la plataforma descrita en el proyecto, abarcando temas como el diagnóstico de una persona a través de una mamografía; tomando en cuenta características que se reflejan en la imagen además de unas externas a ella.

La aplicación toma una imagen digitalizada la cual es procesada para la lectura de las características seleccionadas para el diagnóstico. Dicha aplicación resalta "manchas" de la imagen las cuales son resultado de una comparación entre una imagen de referencia y la imagen a estudiar o son secciones de la imagen que rompen con la armonía del resto de la imagen. De las manchas son determinadas algunas características como la forma de la masa, tamaño y densidad para así corroborar si en realidad se trata de una anomalía considerada para el diagnóstico o de tejido mamario regular. Estas decisiones son tomadas gracias a una red neuronal artificial diseñada para identificar el tipo de anomalía que se está manifestando.

Con la información resultante se obtiene una segunda clasificación, con una segunda red neuronal artificial la cual se encarga de decidir, de acuerdo a un entrenamiento previo, la categoría BI-RADS a la que pertenece dicho paciente.

Se obtienen resultados satisfactorios, un porcentaje del 86.20 % de eficiencia en el Diagnóstico de mamografías.

Palabras claves: Anomalías en mama, categoría BIRADS, diagnóstico, mamografía, Procesamiento de Imagen, Red Neuronal Artificial.



Abstract

The document describes the process undertaken for the development of the platform described in the project, covering topics like the diagnosis of a person through a mammogram; taking into account characteristics which are reflected in the image plus some external to it.

The app takes a digital image which is processed for reading selected characteristics for diagnosis. The app highlights "blobs" of the image, which are the result of a comparison between a reference image and the image to study, or, this blobs are sections of the image that break the harmony of the rest of the image. Of these blobs, characteristics like the shape of the mass, size and density are determine in order to confirm whether this is actually an anomaly considered for the diagnosis or regular breast tissue. These decisions are made by an artificial neural network designed to identify the type of problem that is manifesting.

With the resulting information a second classification is obtained with a second artificial neural network which is responsible for deciding, according to previous training, the BI RADS category to which that patient belongs.

Satisfactory results are obtained, a percentage of 86.20% efficiency in the diagnosis of mammograms.

Key Words: Abnormalities in breast, BIRADS category, diagnosis, mammography, image processing, Artificial Neural Network.



1 Introducción.

El cáncer de mama es una de las principales causas de mortalidad hospitalaria por tumores malignos en la población de 20 años y más (18.7 por ciento) para 2013. Es una de las enfermedades que no hacen distinción entre la población de países desarrollados y en desarrollo y es el tipo de cáncer con mayor presencia en las mujeres a nivel mundial. En cuanto a la mortalidad por esta enfermedad, sí hay diferencias: en países de bajos ingresos ocurren la mayoría de los decesos, ya que generalmente el diagnóstico se realiza en fases avanzadas de la enfermedad, debido a la falta de acceso a servicios de salud y a la poca sensibilización para la detección precoz (conocimiento de signos, de síntomas iniciales y la autoexploración mamaria). Datos de la Organización Mundial de la Salud (OMS, 2015c) señalan que cada año se detectan 1.38 millones de casos nuevos y ocurren 458 mil muertes por esta enfermedad [1].

Tabla 1 Distribución porcentual de morbilidad hospitalaria de la población de 20 años y más, por tumores malignos según sexo.

Distribución porcentual de morbilidad hospitalaria de la población de 20 años y más por tumores malignos según sexo 2013			
Tumores malignos	Total	Hombres	Mujeres
Total	100.0	100.0	100.0
Mama	18.7	0.7	29.5
Órganos digestivos	18.0	25.0	13.8
Órganos genitales femeninos	11.7	NA	18.6
Órganos hematopoyéticos	7.6	10.6	5.8
Células germinales (testículos u ovarios)	6.6	6.4	6.7
Tejido linfático y afines	7.0	9.9	5.2
Órganos respiratorios e intratorácicos	4.9	8.5	2.8
Otros tumores malignos*	25.5	38.9	17.6

Nota: Se utilizó la Clasificación Estadística Internacional de Enfermedades y Problemas relacionados con la salud (CIE-10), código C00-C97.

*Incluye las neoplasias de labio, cavidad bucal y faringe (C00-C14); huesos y cartílagos articulares (C40-C41); piel (C43-C44); tejidos mesoteliales y tejido blandos (C45-C49); órganos genitales masculinos (C60-C63) vías urinarias (C64-C68); ojo, encéfalo y otras partes del sistema nervioso central (C69-C72); glándula tiroides y otras glándulas endocrinas (C73-C75); de sitios mal definidos, secundarios y de sitios no especificados (C76-C80); y de sitios múltiples independientes (C97).

Fuente SSA (2013). Base de Egresados Hospitalarios 2013. Proceso INEGI.

La causa del cáncer de mama es multifactorial, es decir, no se puede identificar una causa o razón única que desencadene su aparición y desarrollo posterior. La genética implica solo una pequeña parte del total de casos, mientras que casi 21% de ellos son atribuibles a alcohol, sobrepeso, obesidad y falta de actividad física (IMSS, 2015; OMS, 2015a).

Debido a no haber una sola causa, es preciso la prevención mediante hábitos sanitarios junto a la detección temprana de tumores e la mama mediante la autoexploración y el cribado. La autoexploración refiere a una técnica sencilla que debe realizarse mensualmente para detectar cambios en la forma o textura de las mamas, aureola o pezón, el engrosamiento de la piel o masas debajo de ella, hoyos, secreciones del pezón, piel escamosa o hinchada. (Breastcancer.org, 2012). Por su parte, el cribado hace referencia al empleo de pruebas sencillas en una población sana que tienen por finalidad detectar sistemáticamente a las personas que, aún sin síntomas, padecen una enfermedad. En el caso del cáncer de mama, la mastografía o mamografía, es la más común. A partir de un resultado positivo en esta prueba, es que se inicia la confirmación del diagnóstico, generalmente por medio de una biopsia, y comienza el tratamiento buscando que ambos se den en una fase temprana de la enfermedad (OMS, 2015b) [1].

Toda mamografía es valorada por un médico especializado en el área; aun así existe una diversidad de opiniones de un médico a otro, tomando en cuenta sus estudios y experiencia. Debido a esta variedad de diagnósticos, cabe la posibilidad que ser diagnosticado con un falso positivo o falso negativo, y es ahí donde se perjudica al paciente.

El desarrollo de esta plataforma tiene el objetivo de ser un punto de partida para servir de apoyo para el diagnóstico del paciente a partir de la misma mamografía digitalizada, y así disminuir la variación de diagnósticos. Para esto, se valora la mamografía digitalizada, pasando por una rutina de procesamiento de imagen y así obtener la información necesaria para el diagnóstico. Características como el tamaño, forma, densidad de ciertas áreas de la imagen, en conjunto con agentes externos a ella, como si el paciente se ha palpado alguna masa o si ya ha sido diagnosticado con cáncer como resultado de otro medio, son procesadas por una Red Neuronal Artificial entrenada para obtener como resultado el tipo de anomalía se presenta en la imagen. Una segunda Red Neuronal Artificial es desarrollada para que a partir del tipo de anomalía que



describa la primera red, entre a una segunda clasificación y tener como resultado la categoría a la que pertenece el paciente de acuerdo a las Categorías BI-RADS ya establecidas.

1.1 Planteamiento del problema

Debido a que la forma de detección de cáncer de mama o alguna otra anomalía es a través de imagenología, mastografías o mamografías, existe puntos o normas ya establecidas para estudiar e identificar el posible problema, las cuales son valoradas por un médico encargado basado en su experiencia y criterio, lo cual permite una variación de diagnósticos que resulta perjudicial para el paciente.

1.2 Objetivos de la investigación

1.2.1 Objetivo general

- ❖ Desarrollar un aplicación en C# capaz de identificar la existencia de una anomalía a partir de una mastografía o mamografía digitalizada. Además de clasificar dichas anomalías según el criterio de las Categorías BI-RADS.

1.2.2 Objetivos específicos

- ❖ Capacidad de lectura de imágenes en formato Dicom (.dcm)
- ❖ Tratamiento de imágenes para su estudio, incluyendo aplicación de filtros, apertura y cierre morfológico.
- ❖ Identificar área con anomalía en la imagen.
- ❖ Identificar las características del área.
- ❖ Definir el tipo de anomalía de acuerdo a las características del área.
- ❖ Definir la categoría de la anomalía de acuerdo a los estándares establecidos en BI-RADS.



1.3 Formulación de Hipótesis

Es posible identificar y clasificar las anomalías detectadas en una mastografía o mamografía digitalizada a través de procesamiento de imágenes digitales e Inteligencia Artificial.

1.4 Justificación

En 2013, el Distrito Federal es la entidad con el mayor número de mastografías realizadas con 30 de cada 100 que se hacen en el país. En el año 2014 por cada caso nuevo de cáncer de mama en los varones se detectan 29 en las mujeres. Durante 2013, el tumor maligno de mama es la segunda causa de mortalidad por neoplasias en las mujeres de 20 años y más (14.8 por ciento). Las tasas de mortalidad por este cáncer se incrementan conforme aumenta la edad. En 2013, 63 de cada 100 mil mujeres de 80 y más años fallecen a causa de esta enfermedad [1].

En la actualidad se cuenta con una diversidad de técnicas utilizadas para la captura de imágenes médicas empleadas como auxiliares para detectar alguna anomalía en tejido mamario, sin embargo el detectar alguna anomalía depende de la experiencia del técnico siendo un método ambiguo; es por esto que este proyecto pretende desarrollar una herramienta computacional que ayude al diagnóstico a través de análisis de las imágenes médicas por medio de procesamiento de imagen e inteligencia artificial. Detectando de manera automática posibles áreas afectadas y la categoría a la que pertenece dicha anomalía de acuerdo a los parámetros obtenidos a través del procesamiento de la imagen y la inteligencia artificial.

El objetivo de este proyecto es proporcionar una ayuda de manera independiente del grado de precisión que el proporcionado por la experiencia; tratando de dar una mejor base para un diagnóstico, ya que debemos de recordar que ninguna técnica para la captura de imagen de tejido mamario dictamina si la anomalía es cáncer o no, solo son una pauta para indicar si existe posibilidad de un cáncer y en seguida realizar más estudios hasta llegar a la necesidad de una biopsia.



1.5 Antecedentes

Para este trabajo se hizo un análisis de proyectos en la red que fueran útiles para el desarrollo de este.

1.5.1 Análisis del Cáncer de Seno usando técnicas de procesamiento de imagen.

El trabajo se concentra en procesamiento de imagen utilizando Matlab, convirtiendo una mamografía en una matriz 3D, usando técnicas como celdas, brechas de llenado, brechas de dilatación, remover bordes, suavizando el objeto, encontrando estructuras y extrayendo objetos grandes. Finalmente encontrando la Granulometría de tejidos en una imagen sin segmentar explícitamente cada objeto [2].

Existen varias señales para detectar cáncer observando una mamografía, La principal señal es una distorsión local del tejido glandular y existencia de micro calcificaciones malignas. La atenuación del tumor puede variar dependiendo del tipo de tumor. Un tumor es usualmente redondo con bordes distintos. Mientras que un tumor maligno tiende a ser de forma irregular con bordes difusos. Generalmente 2 senos de una mujer son muy parecidos y tener cáncer en los 2 senos es relativamente raro. Este hecho ayuda al radiólogo en la búsqueda de cáncer en una mamografía [2].

A continuación en la Fig. 1.1 muestra un diagrama del análisis propuesto por el autor para la detección de cáncer en mamografías.



Fig. 1.1 Diagrama de análisis de distribución para detección de cáncer en mamografía.

Microcalcificación usando procesamiento de imagen:

En la Fig. 1.2 se visualiza la dinámica a utilizar para el procesamiento de imagen y la detección de microcalcificaciones propuesta por el autor.

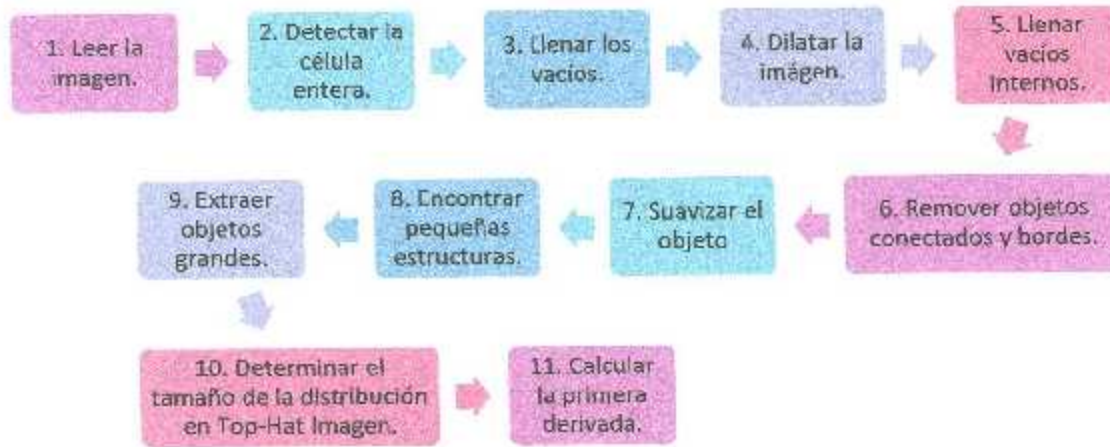


Fig. 1.2 Diagrama de procesamiento de imagen para detectar microcalcificaciones:

Como resultado del proceso propuesto en la Fig. 1.2 se obtiene como resultados las imágenes mostradas en la Fig. 1.3 que se muestra a continuación.




Fig. 1.3 Imágenes resultantes del procesamiento de imagen digital, a) Imagen Original, b) Imagen con detección de bordes, c) Imagen con llenado de espacios vacíos, d) Imagen resultante final [2].

1.5.2 Detección de Cáncer de seno en mamografías usando funciones de procesamiento de imagen.

Las mamografías funcionan con valores de niveles de gris, la imagen original (Fig. 1.4) es segmentada con la función `threshold`, segmentación de edge-based y segmentación `watershed` [3].



Fig. 1.4 Imagen original detección de cáncer con funciones de Matlab [3].

Se utiliza el Software de Matlab para implementar el algoritmo.




Fig. 1.5 Estructura tipo diamante [3].

El proceso descrito en el artículo se resume en la Fig. 1.6, donde muestra paso a paso las acciones propuestas y las funciones utilizadas [3].

Paso 1

- Leer la imagen y convertirla en una matriz, cada valor representa una función bidimensional de intensidad de luz $f(x,y)$.

Paso 2

- Crear una estructura elemental, para aplicar dilatación y erosión. La estructura consiste en 0's y 1's que pueden tener cualquier forma y tamaño.
- $\text{origin} = \text{floor}((\text{size}(\text{nhood})+1)/2)$
- Se utiliza la función `strel` para crear la forma de diamante (Fig. 1.5)

Paso 3

- Se utiliza la función `imbothat` para mejorar el contraste de la imagen, el cual regresa la transformación `top-hat` y `bottom-hat`.
- `ltop=imtohat(afm,se)`
- `lbot=imbothat(afm, se)`

Paso 4

- Exagerar los vacíos entre objetos, el `top-hat` contiene los picos de los objetos que encajan el elemento estructural; para esto se utiliza la función `imbothat` que muestra el vacío entre los objetos. Para maximizar el contraste entre objetos y vacíos se adiciona el `top-hat` de la imagen a la original y después se susrae el `bottom-hat` del resultado.
- `lenhance=imsubtract(imadd(ltop,afm),lbot)`

Paso 5

- Convertir el objeto de interés, para lo cual se usa la transformación `watershed` que detecta los valles de intensidad en la imagen, para lo cual se mejora la imagen resaltando los valles de intensidad usando la función `imcompleent`.

Paso 6

- Después, detectar todos los valles más profundos que un umbral con la función `imextendedmin`. La salida de esta función es una imagen binaria.
- La función `imimposemin` cambia los valores de los píxeles del valle a cero (en más bajo valor de imágenes unil 8).

Paso 7

- La función `watershed` devuelve una matriz que contiene números no negativos que corresponden a la cuenca divisora. Los píxeles que no corresponden a ninguna cuenca son píxeles con valor cero.
- `war=watershed(limpose)`
- Para visualizar esa matriz se convierte a una imagen a color con la función `label2rg`.

Fig. 1.6 Diagrama de procesamiento de imagen para la detección de masas [3].

1.5.3 Identificación de Masas Anormales en imágenes digitales de mamografías.

El artículo se concentra en desarrollar una técnica para identificar el anormal crecimiento de masas en seno usando simples algoritmos. La herramienta solo identificara las masas con ciertas características. En experiencia del autor se debe de considerar los 3 tipos de tejido; graso, glandular- graso y glandular-denso. Diferentes tipos de anomalías como calcificaciones, bien definidas o masas circulares, masas especulativas y otros tipos de masas son consideradas para su estudio [4].

Para la lectura de una mamografía se realiza una mejora en la calidad (Fig. 1.7) de imagen al utilizar segmentación dando resultados más precisos. El primer paso es remover las partes no deseadas del fondo de la mamografía. Remover las partes innecesarias se logra incrementando el contraste de la mamografía usando el valor del umbral [4].



Fig. 1.7 Diagrama para mejorar la imagen [4].

Mediante el análisis de la imagen, se segmenta la imagen en pequeños bloques. Para reducir la complejidad del algoritmo se degrada la imagen a un bloque de 2x2 pixeles. Se checa la intensidad del valor del pixel del bloque y se obtiene el valor más alto el cual se propagará por todo el resto del bloque y ahora la mamografía se compone de bloques de 2x2. Dicho proceso se ejemplifica en la Fig. 1.8.



Fig. 1.8 Formación de bloques homogéneos 2x2 [4].

Ahora los bloques de 2×2 homogéneos hacen un arreglo para obtener un bloque de 4×4 pixeles que contienen 4 bloques de 2×2 homogéneos, y se hace el mismo procedimiento. Ahora la imagen de la mamografía se compone de bloques de 4×4 homogéneos. Se repite el proceso para ahora obtener bloques de 8×8 homogéneos.

La técnica de cuantificación de color uniforme es usada para romper el espacio de color de la mamografía en 8 regiones de tamaño igual. Aunque este es un proceso con pérdidas, este es utilizado [4].

Como se observa en los artículos anteriores, en su mayoría se hace uso de funciones de Matlab para tratar la imagen y resaltar el área de interés; así mismo solo se enfocan en un tipo de masa además de solo tratar con una sola imagen, lo cual deja al aire otros tipos de masa también considerados con probabilidad de cáncer. A diferencia de estos, este proyecto abarca más variedad de anomalías consideradas benignas y malignas, además de tratar con imágenes que no presentan alguna alteración en el tejido, logrando así una categorización más amplia.



2 Mamografías, Diagnóstico y Calcificación

2.1 Mamografías y su diagnóstico.

La mamografía o mastografía es una imagen de rayos X del seno o mama la cual es usada para determinar y evaluar los cambios en el tejido de la glándula mamaria [5]. Se categoriza en dos tipos, escrutinio o de detección, que es el tipo de estudio realizado a pacientes sanos con el fin de encontrar indicios de cáncer en etapa temprana [6]. A la segunda categoría llamada mamografía de diagnóstico es utilizada a partir de algún síntoma o signo de una sospecha de cáncer [6]. Este tipo de mamografía provee información acerca de la localización, número y características de la lesión con el objetivo de dar una opinión acerca del área sospechosa [6, 7].

2.1.1 Cambios de tejido mamario observables en una mamografía.

Las mamografías son interpretadas por médicos radiólogos, los cuales para interpretarla realiza una comparación con mamografías anteriores, o en dado caso que sea la primera mamografía en el historial médico, se realiza la comparación con la imagen de la otra mama [1].

Los signos observables en una mamografía que demuestran anomalías, son calcificaciones, nódulos o masas, asimetría en la densidad, y/o distorsión de la arquitectura.

2.1.1.1 Calcificaciones

Son pequeñas deposiciones de mineral entre el tejido mamario. Lucen como un pequeño punto blanco en la mamografía. Estos pueden causar o no cáncer y existen 2 tipos macrocalcificaciones y microcalcificaciones [5].

Una macrocalcificación es un depósito de calcio grueso, de gran tamaño, redondas, con bordes lisos y se visualizan con facilidad, que en la mayoría de los casos viene



acompañado de cambios en el tejido mamario. Estos depósitos están relacionados a condiciones no cancerosas y no requiere biopsia. Por lo contrario la microcalcificación es un espectro de calcio en el seno, pequeño, de diversas formas y miden menos de 0.5 mm. Encontrar microcalcificaciones en una mamografía es más preocupante que las macrocalcificaciones aunque estas no siempre signifiquen que el cáncer está presente. La forma y diseño de estas ayudan al médico a evaluar que tan probable es que el cáncer este presente [5, 8].

2.1.1.2 Masa

Una masa son áreas que luzcan anormales y pueden ser varias posibilidades, incluyendo quistes y tumores no cancerosos. Los quistes puede ser sacos de fluido o solido; el tamaño, forma y márgenes de la masa ayudan a determinar el tipo de quiste que se presenta en la mamografía [5].

2.1.1.3 Densidad de la mama.

La densidad de la mama se basa en que tan fibrosa y tejido glandular se encuentre el tejido mamario en conjunto con que tanto tejido graso forma el seno. Un seno denso no es una anomalía, pero existe la posibilidad que esté ligado a un alto riesgo de cáncer de seno [5].

2.1.2 Categorización de Mamografías.

El *American College of Radiology* (ACR), diseñó una manera estándar de describir los resultados encontrados en las mamografías. Este sistema es llamado *Breast Imaging Reporting and Data system* (BI-RADS), el cual cuenta con categorías enumeradas del 0 al 6.

Esta categorización depende de las anomalías encontradas en la imagen y de las características de dicha anomalía, al igual que es considerado la localización de la anomalía (Fig. 2.1).




Fig. 2.1 Planos referenciados a mama derecha [8].

2.1.3 Léxico Mamográfico

Los hallazgos mamográficos se clasifican en 6 apartados, de los cuales solo mencionaremos 2 las cuales fueron seleccionadas para el estudio de este proyecto.

1. Masa: se define como una lesión ocupante de espacio en dos proyecciones. Existe un descriptor (morfología) y dos modificadores (margen y densidad) [9].
 - Morfología: Redonda, ovalada, lobulada o irregular (Fig. 2.2).




Fig. 2.2 Morfología de masa [8].

- Margen: circunscrito, microlobulado, oscurecido por el parénquima adyacente, mal definido o espiculado (Fig. 2.3).



Fig. 2.3 Margen [6].

- Densidad (en relación al tejido mamario adyacente): alta densidad, isodenso, baja densidad, de contenido graso (Fig. 2.4).



Fig. 2.4 Densidad de masa [10].

Por lo tanto se tiene la siguiente clasificación de las masas de acuerdo a los BI-RADS (Fig. 2.5):

Categorías BI-RADS Nódulos.				
BI-RADS	DESCRIPCIÓN	VPP	HALLAZGOS	SUGERENCIA
BR-1	mama normal			
BR-2	patología benigna			control habitual
BR-3	superiormente benignidad	5%		control mensual
BR-4A	baja a moderado sospecha	5% 2 al 10%		Resección histológica
BR-4B	moderada sospecha	35%		estudio histológico
BR-4C	moderada a alta sospecha	70% 41 al 94%		estudio histológico
BR-5	alta sospecha	95%		estudio histológico
BR-6	malignidad confirmada	100%	anatomía patológica positiva	No hay sugerencia
BR-0	estudio insuficiente	???	???	el tecnólogo ecografía

Fig. 2.5 Nódulos, categorías BI-RADS [9].



2. Calcificaciones: se clasifican según su morfología y distribución (Fig. 2.6).

- Típicamente benignas: se incluyen las calcificaciones cutáneas, vasculares, en palomita de maíz, secretoras, redondeadas, en cáscara de huevo, intraquísticas, las suluras calcificadas y las calcificaciones distróficas.
- Sospecha intermedia: se definen dos tipos: amorfas y groseras heterogéneas
- Alta sospecha de malignidad: calcificaciones finas pleomórficas y finas lineales o ramificadas [9].

Categorías BIRADS 2004. Calcificaciones.		Román Rostagno y col.				
BIRADS	DESCRIPCIÓN	VPP	HALLAZGOS			SUGERENCIA
BR-1	mama normal		calcificaciones benignas	calcificaciones benignas	calcificaciones benignas	control habitual
BR-2	patología benigna		calcificaciones benignas	calcificaciones benignas	calcificaciones benignas	control habitual
BR-3	Sugestiva de benignidad	< 2%	calcificaciones benignas	calcificaciones benignas		control 6 meses
BR-4A	baja a moderada sospecha	5% 2 al 10%	calcificaciones benignas			Punción histológica
BR-4B	moderada sospecha	35% 11 al 40%	calcificaciones benignas	calcificaciones benignas	calcificaciones benignas	estudio histológico
BR-4C	moderada a alta sospecha	70% 41 al 94%	calcificaciones benignas	calcificaciones benignas		estudio histológico
BR-5	alta sospecha	95%	calcificaciones benignas			estudio histológico
BR-6	malignidad confirmada	100%		anatomía patológica positiva		No hay sugerencia
BR-0	estudio insuficiente			microcalcificaciones		magnificación

Fig. 2.6 Nórdulos, Clasificación BI-RADS [9].

CATEGORÍA 0: ES NECESARIA EVALUACIÓN DE IMAGEN ADICIONAL Y/O COMPARACIÓN CON MAMOGRAFÍAS ANTERIORES.

Esto indica que la anomalía puede que no sea clara para definir y es necesario más pruebas. Esto puede indicar la necesidad de comparar la imagen con imágenes anteriores [11]. Un ejemplo se muestra en la Fig. 2.7 donde con los resultados obtenidos de la mamografía no se obtiene un diagnóstico preciso, por lo que se orienta al paciente a otro tipo de estudios.




Fig. 2.7 Mama Categoría BI-RADS 0 [11].

CATEGORÍA 1: NEGATIVO

No hay reporte de alguna anomalía (Fig. 2.8). El seno luce igual, sin ninguna masa, estructuras distorsionadas o sospecha de calcificación [5].




Fig. 2.8 Mama Categoría BI-RADS 1 [10]

CATEGORÍA 2: BENIGNO (NO CANCEROSO).

Este también es un resultado negativo, no existe cáncer, pero se reporta que es una masa benigna, además de calcificaciones benignas, ganglios intramamario. Esta información es registrada para mamografías futuras [5].

CATEGORÍA 3: PROBABILIDAD DE BENIGNIDAD ENCONTRADA. SEGUIMIENTO EN UN CORTO PERIODO ES SUGERIDA.

Se cuenta con gran posibilidad de benignidad (Fig. 2.9). Los hallazgos encontrados no sugieren un cambio al transcurrir el tiempo pero al no ser declarado enteramente benigno se hace una segunda prueba, por lo general en 6 meses [5].



Fig. 2.9 Mama Categoría BI-RADS 3 [10].

CATEGORÍA 4: SOSPECHA DE ANORMALIDAD. CONSIDERAR BIOPSIA.

Resultado dudoso de malignidad (Fig. 2.10). Requiere una confirmación histopatológica. Consta de 3 grados de acuerdo con su porcentaje de malignidad que van del 3 al 94%[5].

1. 4A: Baja sospecha de malignidad. 3 a 49% [11].
2. 4B: Sospecha intermedia de malignidad. 50 a 89% [11].
3. 4C: Sospecha moderada de malignidad. 90 a 94% [11].



Fig. 2.10 Mama Categoría BI-RADS 4 [10].

CATEGORÍA 5: ALTA SOSPECHA DE MALIGNIDAD. REQUIERE BIOPSIA PARA CONFIRMAR DIAGNÓSTICO.

Existe al menos 95% de ser un cáncer [5]. Ejemplificado en la Fig. 2.11 donde cumple con las características de ser un cáncer, sin embargo se requiere una biopsia para confirmar el resultado.



Fig. 2.11 Mama Categoría BI-RADS 5 [10].

CATEGORÍA 6: MALIGNIDAD COMPROBADA POR BIOPSIA.

Las mamografías de esta categoría son utilizadas para dar seguimiento al tratamiento [5].




Fig. 2.12 Mama Categoría BI-RADS 6 [10].

3 Procesamiento de imágenes digitales

3.1 Representación Digital simple

Se dice que una imagen ha sido digitalizada, ya que por cada región de esta imagen, le corresponde un número que representa la cantidad de luz que fue registrada. Cada región se compone de un renglón y una columna, esto se representa en una matriz de forma $n \times m$ [12].

$$I = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{pmatrix} \quad \text{Ec. (1)}$$

A cada elemento de la matriz le corresponde una propiedad de la imagen; el cual el sistema más simple es el llamado escalas de grises y este registra la cantidad de luz capturada.

Para el registro de una imagen se acostumbra usar formatos que están referenciados por el número de bits que son utilizados para la cuantificación de la cantidad de luz recibida. Cuando se trabaja solo la intensidad de la luz recibida en el detector se dice que la imagen ha sido adquirida en tonos de gris, los tipos más frecuentes son los mostrados en la Tabla 2 [12]:

Tabla 2. Formatos de imagen en bits [12].

Numero de bits	Descripción
1	Imagen monocromática, blanco y negro, alto contraste
4	Imagen de 16 niveles
8	Imagen de 256 niveles

Imágenes con una profundidad de 8 bits se representan con 256 niveles de gris, es decir, un rango (0, 255). Bajo esta representación los elementos de la matriz que representa a la imagen $x_{ij} \in (0 \dots 255)$.

Al punto $x_{ij} = I(i, j)$ se le llama pixel y se debe entender el tono de gris que se ha asociado a la imagen en la coordenada (i, j) de la partición definida por el sistema de digitalización [12].

3.2 Imágenes en escala de grises

La escala de grises es también conocida como escala de intensidades o escala monocromática, donde el pixel es una muestra que contiene información de la intensidad de la imagen. Las características que definen a un color son el tono o matiz, el valor (luminosidad u oscurecimiento) y la saturación. Por lo tanto la conversión de una imagen a color a una imagen en escala de grises se realiza por su acercamiento más común, donde se descartan los valores de tono y saturación y se trabaja con la información de la luminosidad[13].

Tomando en cuenta que el color rojo verde y azul son señales de luminosidad, la aproximación a escala de grises está dada por la ecuación:

$$GRAY = (0.30 * R) + (0.59 * G) + (0.11 * B) \quad \text{Ec. (2)}$$

Donde 0 es el valor de menos intensidad (negro) y 1 es el valor de mayor luminosidad (blanco).

3.3 Filtros digitales

Para el tratamiento de imagen se utilizan los llamados filtros que cumplen las funciones de [14]:

- Suavizar la imagen, reduciendo las variaciones de intensidades entre pixeles.
- Eliminar ruido, donde modifica aquellos pixeles cuyos niveles de intensidad es muy diferente al de los pixeles vecinos.
- Realza la imagen al aumentar las variaciones de intensidades, allí donde se producen.
- Detectar bordes, lo cual consta en detectar los pixeles en donde ocurre un cambio brusco en la función intensidad.

Con dichos objetivos los filtros se pueden clasificar en 2 tipos de filtros, ya sea en el dominio del espacio de trabajo directamente sobre el pixel de la imagen, o en dominio de la frecuencia, donde las operaciones se llevan a cabo en la transformada de Fourier de la imagen.

3.3.1 Filtros en dominio del espacio.

Los filtros en el dominio del espacio pueden clasificarse en [14]:

- Filtros lineales (filtros basados en máscaras de convolución).
- Filtros no lineales.

3.3.1.1 Filtros Lineales

Se define como, dada la imagen $f(x,y)$ y una máscara $w(x,y)$ la imagen resultante $g(x,y)$ consiste en realizar la operación [14]:

$$g(x,y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s,t) f(x+s,y+t) \quad \text{Ec. (3)}$$

Filtro de la media: Es el filtro más simple intuitivo y fácil de implementar para suavizar imágenes que el de la mediana. Se visita cada píxel de la imagen y se reemplaza por la media de los píxeles vecinos. Se puede operar mediante convolución de una máscara determinada.

Las desventajas de este filtro es que puede crear nuevas intensidades de grises que no aparecen en la imagen original; además de ser muy sensible a cambios locales.

Filtro gaussiano: Se usa para emborrar imágenes y eliminar ruido, similar a lo que hace el filtro de media aunque se utiliza una máscara diferente.

$$G(x,y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad \text{Ec. (4)}$$

3.3.1.2 Filtros no lineales

- Mínimo: selecciona el valor más pequeño.
- Máximo: selecciona el valor más alto.
- Mediana: selecciona el valor en la posición intermedia.

Filtro máximo: Selecciona el mayor valor dentro de una ventana ordenada de valores de nivel de gris. Elimina el ruido pimienta (píxeles negros). Aunque sólo funciona cuando el ruido es exclusivamente tipo pimienta además de que tiende a aclarar la imagen

Filtro mínimo: Selecciona el menor valor dentro de una ventana ordenada de valores de nivel de gris. Elimina el ruido sal (píxeles blancos). Pero sólo funciona cuando el ruido es exclusivamente tipo sal además de que tiende a oscurecer la imagen.

Filtro mediana: Utilizada para eliminar ruido de la imagen. Este consta en visitar cada píxel de la imagen y se reemplaza por la media de los píxeles vecinos.



En la Fig. 3.1 se muestra una representación matricial de una imagen digital.

123	100	112	125	100	180	142	112
100	100	180	180	111	234	234	200
112	154	234	123	112	154	234	119
116	234	234	200	116	234	234	200
115	118	125	100	180	142	112	154
120	120	124	154	234	123	116	234

Fig. 3.1 Representación matricial de una imagen.

Elementos vecinos: 123, 112, 154, 200, 116, 234, 100, 180, 142

Orden: 100, 112, 116, 123, 142, 154, 180, 200, 234

Mediana: 142

La Fig. 3.2 muestra la aplicación de la mediana en la matriz.

123	100	112	125	100	180	142	112
100	100	180	180	111	234	234	200
112	154	234	123	112	154	234	119
116	234	234	200	142	234	234	200
115	118	125	100	180	142	112	154
120	120	124	154	234	123	116	234

Fig. 3.2 Representación matricial de una imagen con filtro mediana.

Para aplicar la mediana se cuenta con una formula general para facilitar el cálculo de la misma, formula descrita en la ecuación Ec. 5.

Formula de la mediana:

$$Me = L_i + a * \frac{\frac{n}{2} - F_{i-1}}{F_i} \quad \text{Ec. (5)}$$

Donde:

L_i : Límite inferior de la clase mediana.

a : Amplitud del intervalo.

n : Número total de datos.

F_i : Frecuencia del intervalo mediano.

F_{i-1} : Frecuencia acumulada del intervalo anterior a la mediana.

4 Inteligencia Artificial

Ciencia que nace después de la segunda guerra mundial, en los años 50's. El término Inteligencia Artificial (IA) se pronunció por primera vez por el informático John McCarthy en una conferencia causando gran impacto, en donde define a la IA como la ciencia e ingenio de hacer máquinas inteligentes, especialmente programas de cómputo inteligentes. Sin embargo Alan Turing es considerado como padre de la IA debido a ser uno de los primeros en formular la teoría de las máquinas informáticas, el cual afirmaba que todo lo calculado por el ser humano puede ser hacer una máquina e igualmente por un programa; además de diseñar una Máquina Universal en 1936.

En 1950 Alan Turing promueve una prueba para evaluar hasta cierto punto la inteligencia de un ente. La Prueba de Turing, pone en desafío a una computadora contra un juez humano, la prueba será superada si la persona no logra distinguir si lo que responde es una persona o no.

A través de IA, se desarrollan sistemas expertos que imitan la capacidad mental del ser humano relacionando reglas de sintaxis del lenguaje a base de la experiencia para dar un juicio acerca de un problema.

Actualmente existen 2 métodos para la implementación de la inteligencia artificial:

- Lógica Difusa.
- Redes Neuronales Artificiales.

4.1 Lógica Difusa.

La lógica difusa inicia en 1965 por Lotfi A. Zadeh. Surge como una herramienta para el control de sistemas y procesos industriales complejos y otros sistemas expertos.

Es una lógica alternativa que permite introducir un grado de vaguedad en las cosas que evalúa. Fue diseñada para imitar el comportamiento del ser humano. Permite trabajar con información que no es exacta para poder definir evaluaciones convencionales, contrario a la lógica tradicional que trabaja con información definida.



4.2 Redes Neuronales Artificiales.

El concepto de Red Neuronal Artificial (RNA) está basado en las Redes Neuronales Biológicas. Una Red Neuronal Biológica, es un dispositivo no lineal, paralelo, caracterizado por su complejidad y su tolerancia a fallos. Sus principales características son las siguientes [15]:

- Aprendizaje mediante adaptación de sus pesos sinápticos a los cambios en el entorno.
- Manejo de imprecisión, ruido e información probabilística.
- Generalización a partir de ejemplos.

Las Redes Neuronales Artificiales intentan imitar estas características. Cada neurona es un procesador elemental con operaciones muy primitivas como la suma ponderada de sus pesos de entrada y la amplificación o umbralización de esta suma [16].

En las RNA, el elemento procesador es la unidad similar a la neurona biológica. Este elemento cuenta con varias entradas que son sumadas y procesadas por una función de transferencia para dar como resultado la salida del elemento procesador [16].

Las salidas del elemento procesador pueden ser conectadas a las entradas de otra neurona artificial a través de conexiones ponderadas que corresponden a la eficiencia de la sinapsis de las conexiones neuronales.

Una Red Neuronal Artificial consiste en un conjunto de unidades elementales conectadas de una forma concreta operando en paralelo (Fig. 4.1), cuya función es determinada por la estructura de la red, fuerza en las conexiones y el procesamiento realizado por los elementos computacionales en los nodos [15]. Por lo general los elementos están organizados en grupos llamados niveles o capas [16].

Una Red Neuronal viene caracterizada por su topología, por la intensidad de la conexión entre sus pares de neuronas llamada pesos, por las propiedades de los nodos y por las reglas de actualización de pesos. Las reglas de actualización son



llamadas también como reglas de aprendizaje, controlan los pesos y estados de los elementos de procesados (neuronas) [15].




Fig. 4.1 Ejemplo de una red neuronal artificial [17].

4.2.1 Ventajas de las Redes Neuronales Artificiales.

Por su constitución, las redes neuronales artificiales presentan características semejantes a las del cerebro. Por lo que proporciona ventajas de las que se incluyen [17]:

- Aprendizaje Adaptativo. Capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.
- Auto-organización. Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.
- Tolerancia a fallos. La destrucción parcial de una red conduce a una degradación de su estructura.
- Operación en tiempo real. Los cálculos neuronales pueden ser realizados en paralelo.
- Fácil inserción dentro de la tecnología existente.

Una red neuronal artificial debe de pasar por reglas de aprendizaje para obtener el valor de salida esperado [18]. Existen 3 tipos de aprendizaje:

- Aprendizaje Supervisado.
- Aprendizaje no Supervisado.
- Aprendizaje por Reforzamiento.

4.2.2 Aprendizaje Supervisado

Se realiza mediante un entrenamiento controlado por un agente externo (supervisor o maestro) que determina la respuesta que debería generar la red a partir de una entrada determinada [18].

Este método de aprendizaje se sub divide en 3 metodologías [18]:

- Aprendizaje por corrección de error.
- Aprendizaje por esfuerzo.
- Aprendizaje Estocástico.

El aprendizaje por corrección de error consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red; es decir en función del error cometido en la salida [17].

$$P = \begin{bmatrix} X1 \\ X2 \\ \dots \\ Xn \end{bmatrix} \quad \text{Ec. (6)}$$

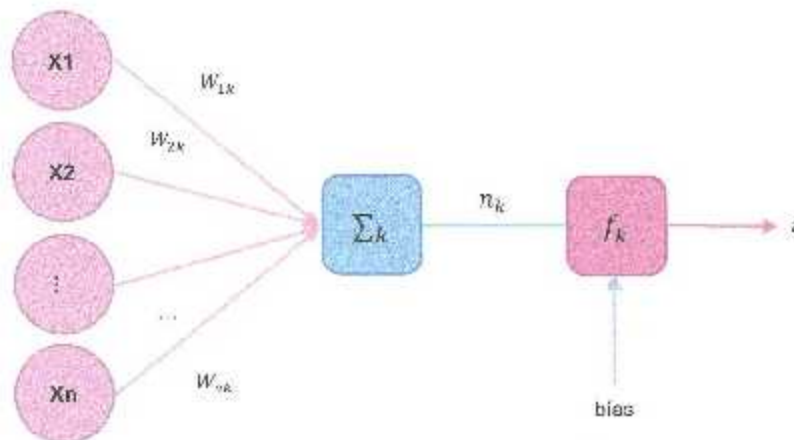


Fig. 4.2 Esquema de una Neurona Artificial.

Del esquema anterior, mostrado en la Fig. 4.2, se deducen las siguientes fórmulas para calcular el valor de salida de la RNA [15]:

$$a = f_k(W_{ij}P_i + b_k) \quad \text{Ec. (7)}$$

Donde se define lo siguiente:

P_i = es el patrón de entrenamiento, donde se compone de las entradas de la red.

W_{ij} = son los pesos de la RNA.

f_k = la función de transferencia aplicada a la sumatoria de los pesos por su entrada.

b_k = es el umbral de activación de la neurona (bías).

Además de contar con la siguiente ecuación, para deducir la conexión que hay entre cada unidad, ya que en la mayoría de los casos se asume que cada unidad recibe contribución de las unidades conectadas a ella [15]:

$$n_k = \sum_j (W_{jk} P_j + b_k) \quad \text{Ec. (8)}$$

Donde:

n_k = es la salida lineal de la neurona.


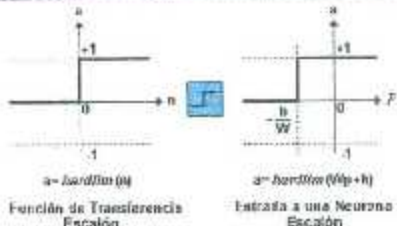
W_{jk} =matriz de pesos.

P_j = patrón de entrenamiento.

b_k = umbral de activación de la neurona (bías).

La función de salida de la red es llamada función umbral o función de transferencia, estas pueden ser de diferentes tipos como se muestran en la Tabla 3 y Tabla 4 [15].

Tabla 3 Funciones de transferencias y sus gráficas.

Nombre	Relación Entrada/Salida	Icono	Gráfica
Limitador Fuerte	$a = \begin{cases} 1 & \text{si } n \geq 0 \\ 0 & \text{si } n < 0 \end{cases}$		 <p> $a = \text{hardlim}(n)$ Función de Transferencia Escalon </p> <p> $a = \text{hardlim}(Wp + b)$ Entrada a una Neurona Escalon </p>


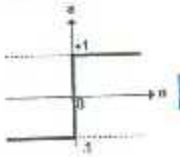
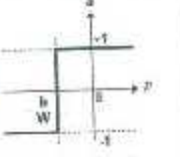

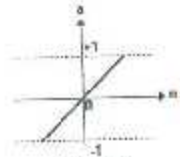
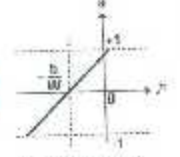

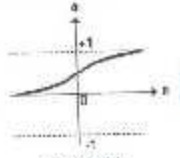
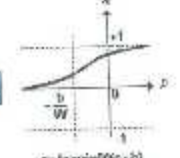





Limitador Fuerte Simétrico	$a = \begin{cases} 1 & \text{si } n \geq 0 \\ -1 & \text{si } n < 0 \end{cases}$		 <p>$a = \text{función}(n)$ Función de Transferencia Escalon Simétrica</p>  <p>$a = \text{función}(Wp+b)$ Entrada a una Neurona Escalon Simétrica</p>
Lineal	$a = n$		 <p>$a = \text{parafin}(n)$ Función de Transferencia Lineal</p>  <p>$a = \text{parafin}(Wp+b)$ Entrada a una Neurona Lineal</p>
Sigmoidal Logarítmica	$a = \frac{1}{1 + e^{-n}}$		 <p>$a = \text{función}(n)$ Función de Transferencia Logarítmica Sigmoidal</p>  <p>$a = \text{función}(Wp+b)$ Entrada a una Neurona Logarítmica Sigmoidal</p>

Tabla 4 Funciones de Transferencia.

Nombre	Relación Entrada/Salida	Icono
Línea Positiva	$a = \begin{cases} 0 & \text{si } n < 0 \\ n & \text{si } n \geq 0 \end{cases}$	
Línea Saturado	$a = \begin{cases} 0 & \text{si } n < 0 \\ n & \text{si } 0 \leq n \leq 1 \\ 1 & \text{si } n > 1 \end{cases}$	
Lineal Saturado Simétrico	$a = \begin{cases} -1 & \text{si } n < -1 \\ n & \text{si } -1 \leq n \leq 1 \\ 1 & \text{si } n > 1 \end{cases}$	
Tangente Sigmoidal Hiperbólica	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
Competitiva	$a = 1$ Neurona con n max. $a = 0$ El resto de las neuronas	

Estas Funciones de Transferencia permiten calcular el valor de salida de la red neuronal.

Los pesos y bias de la RNA son calculados a través de modelos o estructuras de las redes neuronales. Cada uno cuenta con un algoritmo específico para determinar y modificar los pesos y bias ideales de la RNA de modo que la salida que calcula sea igual o similar al valor deseado, es decir, que el error entre la salida calculada y la salida esperada sea muy pequeño. Entre las estructuras más comunes se encuentran:

- Perceptrón Simple
- Perceptrón Multicapa
- Backpropagation
- Etc...

4.2.3 Perceptrón Simple.

Modelo unidireccional, compuesto de dos capas de neuronas, una sensorial o de entradas y otra de salida (Fig. 4.3), con n neuronas de entrada y m de salida [19].

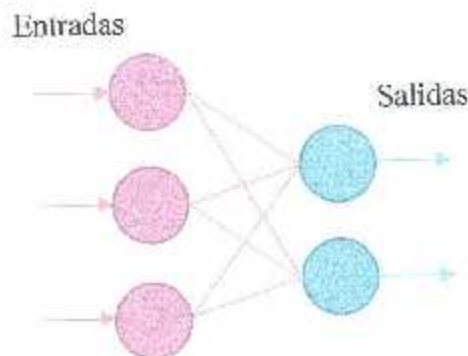


Fig. 4.3 Modelo Perceptrón Simple con n entradas y m salidas.

Donde la salida de la RNA está definida por la siguiente ecuación:

$$y_i(t) = f\left(\sum_{j=1}^n w_{ij}x_j - \theta_i\right), \forall i, 1 \leq i \leq m \quad \text{Ec. (9)}$$

El perceptrón puede utilizarse como clasificador o como para la representación de funciones booleanas. Es fácil ver que una neurona tipo perceptrón solamente permite discriminar entre dos clases linealmente separables. Sea una neurona tipo perceptrón de 2 entradas, x_1 y x_2 con salida y , cuya operación se define [19]:

$$y = f(x_1, x_2, \dots, x_n) = \begin{cases} 1 & \text{si } W_1x_1 + W_2x_2 + \dots + W_nx_n \geq 0 \\ 0 & \text{si } W_1x_1 + W_2x_2 + \dots + W_nx_n < 0 \end{cases} \quad \text{Ec. (10)}$$

Donde la ecuación:

$$x_2 = -\frac{W_1}{W_2}x_1 + \frac{\theta}{W_2} \quad \text{Ec. (11)}$$

Representa una recta que divide el plano en dos regiones, aquellas para las que la neurona proporciona una salida 0 o 1 respectivamente; considerándola como un discriminador lineal que separa dos diferentes clases de patrones.

4.2.2.1 Algoritmo de aprendizaje del Perceptrón simple.

El algoritmo de entrenamiento del perceptrón sigue los siguientes pasos [20]:

- 1.- Se inicializa los pesos y el valor de bias, por lo general se le asigna valores aleatorios a cada uno de los pesos de W_i y al valor de b .
- 2.- Se presenta el primer patrón a la red, junto con la salida esperada en forma de pares entradas/salidas.

$$\{P_1, t_1\}, \{P_2, t_2\}, \dots, \{P_q, t_q\}$$

- 3.- Se calcula la salida de la red.

$$a = f(W_i P_i + b) \quad \text{Ec. (12)}$$

Cuando la red no devuelve la salida correcta es necesario alterar el valor de los pesos.

El proceso de aprendizaje del perceptrón puede definirse en 3 reglas [20]:



Si $t=1$ y $a=0$ entonces

$$W_{nuevo} = W_{anterior} + P \quad \text{Ec. (13)}$$

Si $t=0$ y $a=1$ entonces

$$W_{nuevo} = W_{anterior} - P \quad \text{Ec. (14)}$$

Si $t=a$ entonces

$$W_{nuevo} = W_{anterior} \quad \text{Ec. (15)}$$

Aplicando

$$e = t - a \quad \text{Ec. (16)}$$

Si $e=1$ entonces se aplica la Ec. (13).

Si $e=-1$ entonces se aplica la Ec. (14).

Si $e=0$ entonces se aplica la Ec. (15).

Las ecuaciones anteriores se resumen en la siguiente ecuación en donde se toma en cuenta el error.

$$W_{nuevo} = W_{anterior} + eP \quad \text{Ec. (17)}$$

Y para determinar el bias se cuenta con la siguiente ecuación:

$$b_{nuevo} = b_{anterior} + e \quad \text{Ec. (18)}$$

4.2.4 Backpropagation.

También llamado retro-propagación de errores es un modelo de RNA multicapa, es decir cuenta con una o más capas intermedias entre la capa de entrada y la capa de salida. Una solución al problema de entrenar los nodos de las capas ocultas de las arquitecturas multicapa la proporciona el algoritmo de BP (back-propagation) [19].




Fig. 4.4 Estructura Backpropagation.

Una BP está compuesta por una capa de entrada con n neuronas y una capa de salida con m neuronas y por lo menos una capa oculta de neuronas internas. Cada neurona de las capas ocultas y capas de salida recibe entradas de todas las neuronas anteriores y envía su salida a todas las neuronas de la capa posterior con excepción de la salida como se muestra en la Fig. 4.4. No existe feedback ni laterales entre las neuronas de la misma capa [19].

La función de transferencia mayormente utilizada en esta arquitectura es el la Función Sigmoidal Logarítmica. En este proyecto se hace uso de una arquitectura Backpropagation con la función Sigmoidal Logarítmica.

4.2.4.1 Pasos para el diseño de algoritmo de aprendizaje de una RNA tipo BP.

1. Se aplica un patrón de entrada como estímulo para la primera capa de las neuronas de la red.
2. Se propaga a través de todas las capas superiores hasta generar una salida.
3. Se compara el resultado en las neuronas de salida con la salida esperada y se calcula un valor de error para cada neurona de salida.
4. Estos errores se transmiten hacia atrás, partiendo de la capa de salida hacia todas las neuronas de la capa intermedia que contribuyan directamente a la salida.
5. Este proceso se repite, capa por capa, hasta que todas las neuronas hayan recibido un error que describa su aportación relativa al error total.
6. Basándose en el error recibido se reajustan los pesos de conexión de cada neurona [21].

4.2.4.2 Algoritmo de entrenamiento de una RNA tipo BP.

1. Inicializar los pesos de la red con valores pequeños aleatorios. $t:=0$.
2. Presentar el patrón de entrada y especificar la salida deseada que debe generar la red. Para cada patrón μ del conjunto de aprendizaje:
 - a) Llevar a cabo una fase de ejecución para obtener la respuesta de la red ante el patrón μ -ésimo.



b) Calcular las señales de error asociadas Δ_k^μ y Δ_j^μ .

c) Calcular el incremento parcial de los pesos y umbrales debido a cada patrón μ

3. Calcular la salida actual de la red. Para ello se presentan las entradas de la red y se calcula la salida de capa hasta llegar a la capa de salida, esta será la salida de la red:

a) Calcular entradas netas para las neuronas ocultas procedentes de las neuronas de entrada; para la neurona j oculta:

$$net_{pj}^h = \sum_{i=1}^N W_{ji}^h X_{pi} + \theta_j^h \quad \text{Ec. (19)}$$

Donde:

- h = es la magnitudes de la capa oculta
- el subíndice p al p -ésimo vector de entrenamiento.
- j = la j -ésima neurona oculta.
- θ = puede ser opcional, pues actúa como una entrada más.

b) Se calcula las salidas de las neuronas ocultas:

$$y_{pj} = f_j^h(net_{pj}^h) \quad \text{Ec. (20)}$$

c) Se realiza los mismos cálculos para obtener las salidas de las neuronas de salida:

$$net_{pk}^o = \sum_{j=1}^L W_{kj}^o y_{pj} + \theta_k^o \quad \text{Ec. (21)}$$

$$y_{pk} = f_k^o(net_{pk}^o) \quad \text{Ec. (22)}$$

4. Calcular los términos de error para todas las neuronas.

Si la neurona k es una neurona de la capa de salida, delta es:



$$\delta_{pk}^o = (d_{pk} - y_{pk})f_k^o(\text{net}_{pj}^o) \quad \text{Ec. (22)}$$

La función f se dispone en 2 formas:

La función lineal:

$$f_k(\text{net}_{jk}) = \text{net}_{jk} \quad \text{Ec. (23)}$$

La función Sigmoidal Logarítmica:

$$f_k(\text{net}_{jk}) = \frac{1}{1 + e^{-\text{net}_{jk}}} \quad \text{Ec. (24)}$$

Se selecciona la función dependiendo de la forma que se decida representar la salida: si se desea que las neuronas de salida sean binarias se utiliza la sigmoidal, de lo contrario la lineal.

Para la lineal se tiene que:

$$f_k^{o'} = 1 \quad \text{Ec. (25)}$$

Para la Sigmoidal Logarítmica se tiene que:

$$f_k^{o'} = f_k^o(1 - f_k^o) = y_{pk}(1 - y_{pk}) \quad \text{Ec. (26)}$$

Por lo tanto, para la salida lineal se tiene que:

$$\delta_{pk}^o = (d_{pk} - y_{pk}) \quad \text{Ec. (27)}$$

Para la salida Sigmoidal Logarítmica se tiene que:

$$\delta_{pk}^o = (d_{pk} - y_{pk})y_{pk}(1 - y_{pk}) \quad \text{Ec. (28)}$$



Si j no es la salida, entonces la derivada parcial del error no puede ser evaluada directamente, por lo que se obtiene una expresión en donde el error depende de la capa de salida. De aquí surge el término propagación hacia atrás.

$$\delta_{pj}^h = f_j^{h'}(\text{net}_{pj}^h) \sum_k \delta_{pk}^0 W_{kj}^0 \quad \text{Ec. (29)}$$

5. Actualización de los pesos:

para los pesos de las neuronas de la capa de salida:

$$W_{kj}^0(t+1) = W_{kj}^0(t) + \Delta W_{kj}^0(t+1) \quad \text{Ec. (30)}$$

$$\Delta W_{kj}^0(t+1) = \alpha \delta_{pk}^0 y_{pj} \quad \text{Ec. (31)}$$

para los pesos de las neuronas de la capa oculta:

$$W_{ji}^h(t+1) = W_{ji}^h(t) + \Delta W_{ji}^h(t+1) \quad \text{Ec. (32)}$$

$$\Delta W_{ji}^h(t+1) = \alpha \delta_{pj}^h x_{pi} \quad \text{Ec. (33)}$$

En ambos casos, para acelerar el proceso de aprendizaje se puede añadir un término momento.

6. El proceso se repite hasta que el término error resulte aceptablemente pequeño para cada uno de los patrones aprendidos [22].

$$E_p = \frac{1}{2} \sum_{k=1}^M \delta_{pk}^2 \quad \text{Ec. (34)}$$

Un inconveniente del BP es su lentitud de convergencia, precio a pagar por disponer de un método general de ajuste funcional que no requiere información apriorística.

5 Desarrollo del proyecto

El procedimiento para la elaboración de este proyecto se basa en el siguiente esquema (Fig. 5.1), definiendo en forma general el procedimiento en cada etapa, además de ser una guía para determinar las posibles herramientas a utilizar:



Fig. 5.1 Bosquejo del proyecto.

El proyecto trata imágenes procedentes de mamografías; por lo cual la aplicación diseñada es capaz de trabajar con imágenes tipo DICOM, al igual que otros formatos comunes como .jpeg, .jpg, .png, etc.

Las mamografías o mastografías digitalizadas se encuentran en un formato llamado DICOM por sus siglas en inglés Digital Imaging and Communications in Medicine, creado por ACR (American college of Radiology) y NEMA (National Electrical Manufacturers Association). Este formato es un estándar sugerido de necesidades Usuario-fabricante, que integra un formato digital común, un protocolo de intercambios de datos y una estructura de archivos[23, 24].

Algunos de los atributos que un archivo DICOM proporciona son:

- Nombre del paciente
- Fecha de nacimiento
- Equipo de adquisición
- Situación del paciente
- Contraste empleado
- Tipo de imagen
- Tamaño de la imagen
- Datos de pixel

Este tipo de imágenes son difíciles de conseguir, por lo cual se decide trabajar con mamografías convertidas a imágenes jpg, jpeg, o png; aunque la aplicación esta también diseñada para trabajar con este tipo de archivos.

5.1 Pruebas preliminares

Con la finalidad de definir el procedimiento a seguir para el tratamiento de imágenes, con el objetivo de resaltar el área de interés. Para definir la imagen se realizaron pruebas, tanto con brillos y contrastes, además de filtros, colores y convertir la imagen a blanco y negro. A continuación se muestran las pruebas realizadas.

La siguiente imagen muestra el archivo original (Fig. 5.2), a la cual se procede a hacer el tratamiento:



Fig. 5.2 Imagen original a tratar.

La imagen es sometida a cambios de brillo, tanto hacer mas brillante y oscurecer la imagen las cuales se muestran en la Fig. 5.3:




Fig. 5.3 Imagen con diferentes brillos.

Se procede a mejorar el contraste a hacer pruebas con filtros en dominio del espacio, no lineales de máximo, mínimo y mediana (Fig. 5.4):




Fig. 5.4 Imagen con diferentes contrastes y filtros no lineales.

Para visualizar mejor el área de interés, se cambió la imagen a color (Fig. 5.5):




Fig. 5.5 Imagen a color.

Ahora se procede a cambiar la imagen a una imagen en blanco y negro (Fig. 5.6):

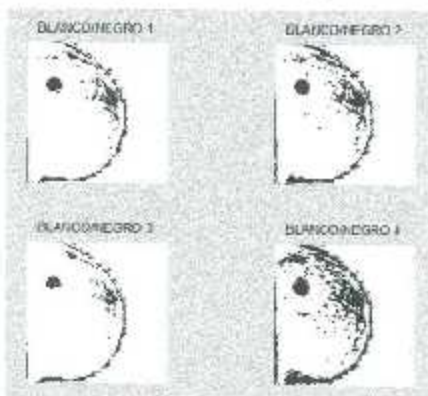


Fig. 5.6 Imágenes en blanco y negro con diferentes umbrales.

La cual se puede representar como una imagen binaria como lo muestra la Fig. 5.7.




Fig. 5.7 Imagen binaria con diferentes umbrales.

Un buen tratamiento de imagen es preciso para definir el área de interés correctamente y proceder a delimitar bordes, definir formas, tamaños, etc. A continuación se muestra un ejemplo de detección de bordes.




Fig. 5.8 Bordes definidos de la imagen binaria.

5.2 Visual Studio Community

Este proyecto consta de desarrollar una aplicación en C# que realice un estudio sobre una mamografía digital, detectar el posible tipo de anomalía que se presente en dicha mamografía, y de acuerdo a los resultados obtenidos, determinar la posible categoría BI-RADS en la que es categorizada la imagen.

Visual Studio es un conjunto completo de herramientas de desarrollo para la generación de aplicaciones web ASP.NET, Servicios Web XML, aplicaciones de escritorio y aplicaciones móviles. Visual Basic, Visual C# y Visual C++ utilizan todos el mismo entorno de desarrollo integrado (IDE), que habilita el uso compartido de herramientas y facilita la creación de soluciones en varios lenguajes. Asimismo, dichos lenguajes utilizan las funciones de .NET Framework, las cuales ofrecen acceso a tecnologías clave para simplificar el desarrollo de aplicaciones web ASP y Servicios Web XML [25].

5.2.1 Lenguaje C#

La sintaxis de C# es muy expresiva, pero también es sencilla y fácil de aprender. La sintaxis de C# basada en signos de llave podrá ser reconocida inmediatamente por cualquier persona familiarizada con C, C++ o Java. Los desarrolladores que conocen cualquiera de estos lenguajes pueden empezar a trabajar de forma productiva en C# en un plazo muy breve. La sintaxis de C# simplifica muchas de las complejidades de C++ y proporciona características eficaces tales como tipos de valor que admiten valores NULL, enumeraciones, delegados, expresiones lambda y acceso directo a memoria, que no se encuentran en Java. C# admite métodos y tipos genéricos, que proporcionan mayor rendimiento y seguridad de tipos, e iteradores, que permiten a los implementadores de clases de colección definir comportamientos de iteración personalizados que el código cliente puede utilizar fácilmente [25].

Como lenguaje orientado a objetos, C# admite los conceptos de encapsulación, herencia y polimorfismo. Todas las variables y métodos, incluido el método Main que es el punto de entrada de la aplicación, se encapsulan dentro de definiciones de clase. Una clase puede heredar directamente de una clase primaria, pero puede implementar cualquier número de interfaces. Los métodos que reemplazan a los métodos virtuales en una clase primaria requieren la palabra clave `override` como medio para evitar redefiniciones accidentales. En C#, una `struct` es como una clase sencilla; es un tipo asignado en la pila que puede implementar interfaces pero que no admite la herencia [25].



5.2.2 Formularios Windows Form y aplicaciones clientes inteligentes.

Con los formularios Windows Forms, puede desarrollar clientes inteligentes. Los clientes inteligentes son aplicaciones muy ricas gráficamente que resultan fáciles de implementar y actualizar, pueden funcionar conectadas o desconectadas a Internet, y pueden tener acceso a recursos en el equipo local de un modo más seguro que las aplicaciones basadas en Windows tradicionales [25].

Los formularios Windows Forms constituyen una tecnología de cliente inteligente para .NET Framework, un conjunto de bibliotecas administradas que simplifican tareas de aplicación comunes, como la lectura y escritura en el sistema de archivos. En formularios Windows Forms, un formulario es una superficie visual en la que se muestra información al usuario. Normalmente las aplicaciones de Windows Forms se generan agregando controles a los formularios y programando respuestas a las acciones del usuario, como clics del mouse o presiones de teclas. Un control es un elemento discreto de la interfaz de usuario que muestra datos o acepta la entrada de datos.

Cuando un usuario hace algo en su formulario o en alguno de sus controles, la acción genera un evento. Su aplicación reacciona a estos eventos utilizando el código y procesa los eventos cuando aparecen.

Los formularios Windows Forms contienen diversos controles que puede agregar a los formularios: controles que muestran cuadros de texto, botones, cuadros desplegable, botones de radio e incluso páginas Web. Si un control existente no satisface las necesidades, los formularios Windows Forms también admiten la creación de controles propios personalizados mediante la clase UserControl.

Para desarrollar una aplicación en C# utilizando Microsoft Visual Community 2015 que sea capaz de tratar un archivo tipo DICOM es preciso manejar una librería para estas acciones. Se utiliza la librería fo-dicom, la cual es librería portable libre disponible en NuGet el cual su instalación es sencilla y desde la plataforma Visual Community. Además con el fin de utilizar herramientas que faciliten el tratamiento de imagen se



utiliza Emgu CV, plataforma de tipo .NET la cual manda a llamar a la librería open-source de visión artificial Open CV, compatible con el lenguaje de programación C# entre otros [26]. Con el mismo propósito de tener herramientas para el manejo y procesamiento de imagen se hizo uso de otra plataforma llamada AForge.NET, que contiene librerías para el procesamiento de imágenes digitales [27].

5.2.3 Descripción General

La aplicación ADAM nombrada así por sus siglas Análisis - Detección de Anomalías en Mama, es desarrollada a por medio de Visual Studio Community 2015, debido a ser una versión gratuita y cumple con las necesidades de desarrollo. Se opta por diseñar la aplicación a través de un formulario Windows Form, el cual es programado bajo el lenguaje C#; esto debido a la familiaridad con el programa y la versatilidad.

ADAM está dedicada a realizar una rutina de procesamiento de imagen con el fin de resaltar las posibles áreas problemáticas visibles en una mamografía. Es importante señalar que la aplicación está diseñada para hacer una comparativa entre a una imagen a estudiar con respecto a una imagen de referencia, ya sea la mamografía de la otra mama o una mamografía anterior de la misma mama, y así visualizar la evolución. En caso de no existir una imagen de referencia, este dato es considerado en el diagnóstico, además de solo resaltar las áreas que el sistema califica como descriptivas para el diagnóstico ya que cumplen con ciertas características.

Después de identificar las áreas posiblemente problemáticas de acuerdo a las características presentadas en la imagen y otras características externas a la imagen ADAM realiza una categorización a través de inteligencia artificial para definir el tipo de posible anomalía que se está presentando en la mamografía. Una segunda categorización es realizada para identificar la posible categoría BI-RADS a la que pertenece dicha mamografía.



La aplicación cuenta con la siguiente ventana principal:



Fig. 5.9 Ventana principal de la aplicación.

Está diseñada para tener 2 imágenes, una imagen de referencia y la imagen a diagnosticar. Debido a que en la mayoría de los casos los médicos radiólogos hacen una comparación ya sea con una mamografía anterior o con la mamografía de la segunda mama para determinar si existe un cambio en el tejido mamario.

ADAM es capaz de abrir imágenes en formato .jpg, .png, así como también imágenes DICOM (.dcm), como lo muestra en la Fig. 5.10, esto por la razón que es un estándar ya establecido y los equipos médicos de imagenología manejan dicho formato DICOM.

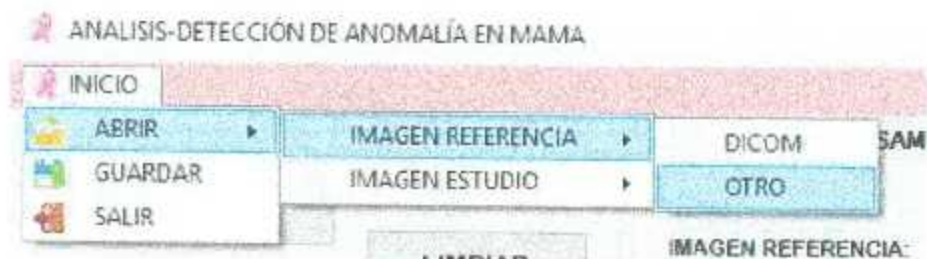


Fig. 5.10 Apertura de imagen de referencia y de estudio en los diferentes formatos.

Para cuestiones de estudio, en la parte superior de la sección donde se visualiza la imagen de referencia y la imagen a estudiar se ubican unas flechas que facilitan el acomodo de las imágenes (Fig. 5.11), permitiendo que estas giren según el sentido de la flecha, para así las dos tengan la misma orientación y correspondan los planos definidos en la parte inferior de la sección (Fig. 5.11). También se visualiza la resolución de la imagen en la parte inferior de la sección (Fig. 5.12).



Fig. 5.11 Botones de giro de acomodo de imagen e indicadores de resolución de las imágenes.




Fig. 5.12 Pantalla anterior con imágenes cargadas en diferentes orientaciones.

En la siguiente figura (Fig. 5.13) se observan las dos imágenes orientadas a la misma dirección para que así correspondan los planos con la imagen.




Fig. 5.13 Imágenes orientadas correctamente.

También se tiene un apartado donde se indican los Datos del Paciente, por el momento solo se tiene la opción de Nombre del paciente y edad del paciente, como se muestra en la Fig. 5.14.

DATOS DEL PACIENTE

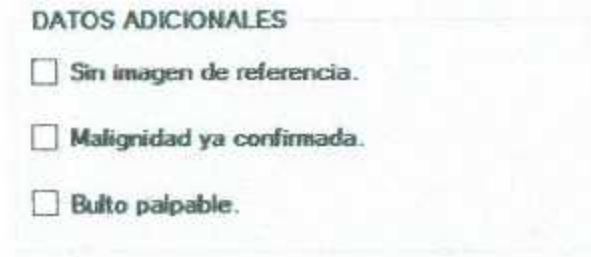
NOMBRE:

EDAD:

Fig. 5.14 Apartado Datos del paciente.

Se cuenta con otra sección, en donde se tiene la opción de indicar otras características del paciente tomadas en cuenta para el diagnóstico del mismo; como si es que se tiene una imagen de referencia para realizar el estudio, si ya ha sido diagnosticado el

paciente con malignidad por otros estudios previos o si el paciente se cuenta con masas palpables. Esto se puede observar en la Fig. 5.15.



DATOS ADICIONALES

Sin imagen de referencia.

Malignidad ya confirmada.

Bulto palpable.

Fig. 5.15 Sección de Datos Adicionales.

Pasando al área de **Control** (Fig. 5.16), se encuentran 3 botones:



CONTROL

PROCESAR

DIAGNOSTICAR

LIMPIAR


 Gire las imágenes para que tengan la misma orientación.

Fig. 5.16 Sección de control de imagen.

Un primer botón llamado **Procesar**, en el cual se encuentra la rutina para realizar el procesamiento de la imagen, que incluye, convertir la imagen a escala de grises, modificar su brillantez, algunas operaciones morfológicas, la aplicación de filtros, delimitación de bordes, así mismo la identificación de las áreas de interés, las cuales se distinguen por romper con la armonía de la imagen. Además de las operaciones anteriores en esta sección se encuentra la rutina para identificar las características que se toman en cuenta en el diagnóstico de la imagen, tales como la forma, densidad, tamaño, plano donde se localiza el área de interés.

Al momento de accionar este botón, se debe de cambiar a la pestaña **Procesamiento** por la cual se visualizan las imágenes después de ser tratadas y caracterizadas las áreas de interés (Fig. 5.17).

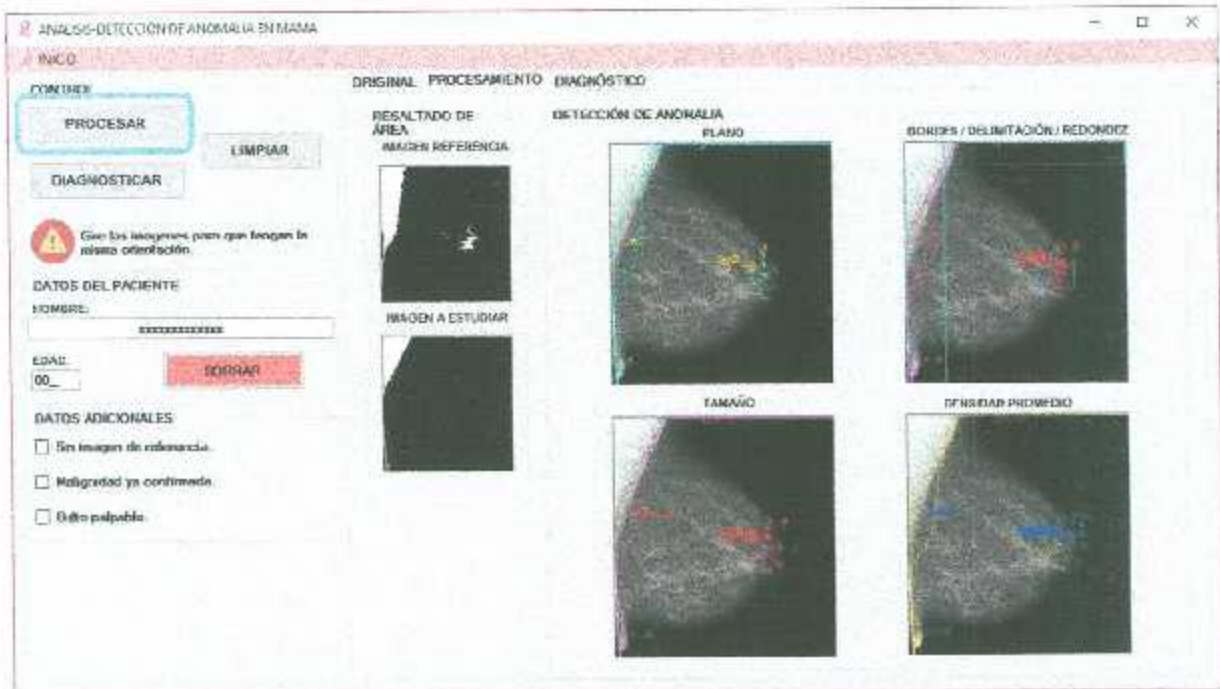


Fig. 5.17 Resultado del Procesamiento de imagen.

En la sección de **Resultado de Área** se observa la imagen de referencia y la imagen a estudiar después de ser tratadas y resaltadas las posibles áreas de interés. A continuación se visualizan 4 secciones más; en la sección **Plano** localiza el plano donde se encuentran las áreas posibles de interés. En la sección **Bordes / Delimitación/ Redondez**, se visualizan las áreas encontradas, delimita sus bordes además de visualizar el índice de redondez de cada área, dando una idea de la forma de esta. Una tercera sección, **Tamaño**, muestra la dimensión en milímetros del área y para finalizar una cuarta sección **Densidad Promedio**, donde muestra la densidad promedio del área. Es de gran importancia indicar si se cuenta con algún dato adicional de los que se muestran en la Fig. 5.15 antes de dar click al botón de Procesar, ya que estos datos también son considerados al momento de hacer un posible diagnóstico.

En la siguiente imagen (Fig. 5.18) se observa activa la pestaña de Diagnóstico, en la cual se visualiza el número de posibles anomalías encontradas y cuantas de cada tipo



se tiene para así dar un resultado y definir en cual categoría pertenece la mamografía a estudiar. Las clasificaciones son definidas a través de dos redes neuronales; una diseñada para definir el tipo de anomalía, y una segunda para definir la categoría BI-RADS a la cual pertenece el conjunto de anomalías. La rutina está contenida dentro del botón **Diagnóstico**. Datos adicionales son utilizados para dar un diagnóstico, tanto para identificar el tipo de anomalía, como para definir la categoría.

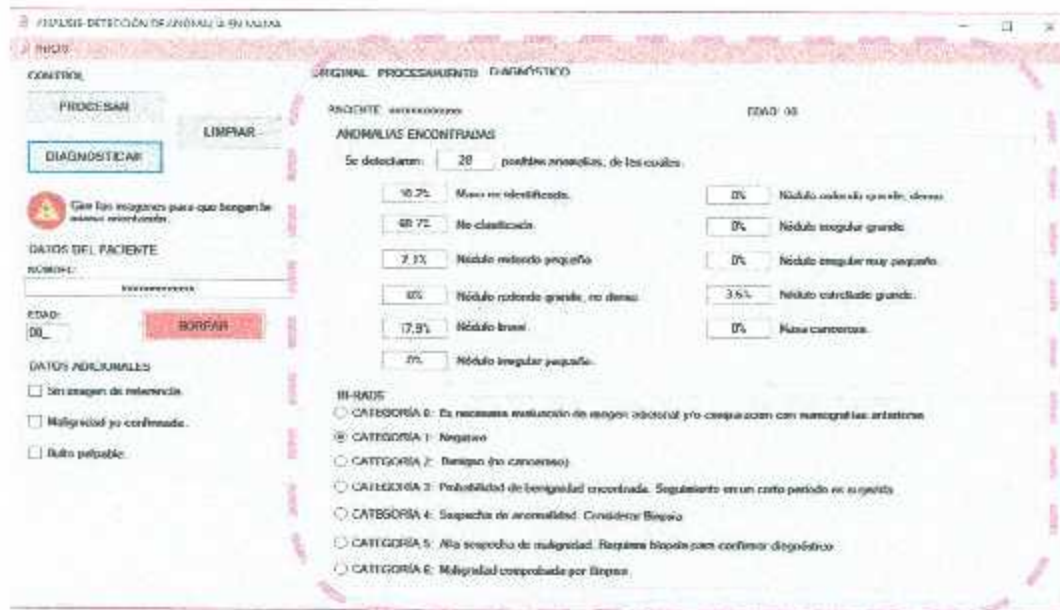


Fig. 5.18 Resultado del Diagnóstico del paciente.

Dentro del menú de inicio existe la opción de Guardar (Fig. 5.19), permite obtener una imagen de la aplicación con los resultados obtenidos del diagnóstico. La imagen resultante tiene la opción de guardarse con un nombre por default que se compone del nombre del paciente, edad del paciente, y fecha del estudio (YYYYMMDD). Para finalizar también se tiene dentro del menú de inicio la opción de Salir, para salir de la aplicación.



Fig. 5.19 Menú de Inicio, opción de Guardar y Salir de la aplicación.

5.2.4 Codificación den C#.

Como ya se mencionó, ADAM es desarrollada en Visual Studio 2015, con un formulario Windows Form programado en C#; anteriormente se explica en forma general el comportamiento de la aplicación además de visualizar la parte grafica de la aplicación.

La codificación de la aplicación se divide en métodos y funciones que se cumplen a través de un evento. Para empezar con el proyecto se declaran las librerías a utilizar, incluyendo las proporcionadas por Fo-Dicom, EMGUCV y AForge.Net (Fig. 5.20).

```
using Dicom.Imaging;
using Emgu.CV;
using Emgu.CV.Structure;
using Emgu.CV.CvEnum;
using AForge;
using AForge.Imaging;
using AForge.Math.Geometry;
```

Fig. 5.20 Librerías a utilizar.

Para abrir una imagen se ha de utilizar 2 rutinas, una que permita abrir una imagen tipo DICOM y la convierta en tipo JPEG para poder trabajar con ella como se muestra en la Fig. 5.21; y una segunda rutina que permite abrir imágenes de otro tipo de formato, como JPG, PNG, etc..., como lo muestra la Fig. 5.22.

```
private void dICOMToolStripMenuItem_Click(object sender, EventArgs e)
{
    OpenFileDialog ABRIR = new OpenFileDialog();
    ABRIR.InitialDirectory = "C:\\";
    ABRIR.Filter = "Archivos DICOM(*.dcm)|*.dcm";

    if (ABRIR.ShowDialog() == DialogResult.OK)
    {
        IMA_REF_0.SizeMode = PictureBoxSizeMode.StretchImage;
        var dicom = new DicomImage(ABRIR.FileName);
        dicom.RenderImage().AsBitmap().Save(@"dicomima.jpg");
        ima_o_ref = new Image<Bgr, byte>(@"dicomima.jpg");
        IMA_REF_0.Image = ima_o_ref.ToBitmap();
        label15.Text = ima_o_ref.Width.ToString();
        label10.Text = ima_o_ref.Height.ToString();
    }
}
```

Fig. 5.21 Abrir imagen tipo DICOM

Los archivos visibles al abrir otro tipo de imagen a la DICOM son JPG, JPEG y PNG como lo muestra la Fig. 5.22.

```
private void jpgToolStripMenuItem_Click(object sender, EventArgs e)
{
    OpenFileDialog ABRIR = new OpenFileDialog();
    ABRIR.InitialDirectory = "C:\\";
    ABRIR.Filter = "Archivos JPG,PNG,JPEG(*.jpg,*.jpeg,*.png)|*.jpg; *.jpeg; *.png";

    if (ABRIR.ShowDialog() == DialogResult.OK)
    {
        IMA_REF_0.SizeMode = PictureBoxSizeMode.StretchImage;
        ima_o_ref = new Image<Sqr, byte>(ABRIR.FileName);
        IMA_REF_0.Image = ima_o_ref.ToBitmap();
        label5.Text = ima_o_ref.Width.ToString();
        label10.Text = ima_o_ref.Height.ToString();
    }
}
```

Fig. 5.22 Código para la apertura de otro tipo de imagen.

Esta rutina se aplica tanto a la apertura de imagen de referencia como a la imagen a estudiar.

Para procesar la imagen, esta es sometida a una serie de operaciones tanto para modificar su color (Fig. 5.23), brillo (Fig. 5.24), así como filtrar la imagen a través del filtro no lineal Mediana (Fig. 5.25), al igual que operaciones morfológicas para definir el área o las áreas de interés.

```
//Convertir a escala de grises
Image<Gray, byte> ima_ref_gris = new Image<Gray, byte>(ima_pro_ref.ToBitmap());
Image<Gray, byte> ima_est_gris = new Image<Gray, byte>(ima_pro_est.ToBitmap());
```

Fig. 5.23 Convertir imágenes a escala de grises.

```
//Brillo
//ima_ref_gris._EqualizeHist();
ima_ref_gris._GammaCorrect(.2d);
//ima_est_gris._EqualizeHist();
ima_est_gris._GammaCorrect(.2d);
```

Fig. 5.24 Modificar brillo de las imágenes.

Para filtrar la imagen, se seleccionó el filtro de la Mediana.

```
//Filtro mediana
Image<Gray, byte> ima_ref_film = ima_ref_gris.SmoothMedian(3);
Image<Gray, byte> ima_est_film = ima_est_gris.SmoothMedian(3);
```

Fig. 5.25 Aplicación de filtro Mediana.

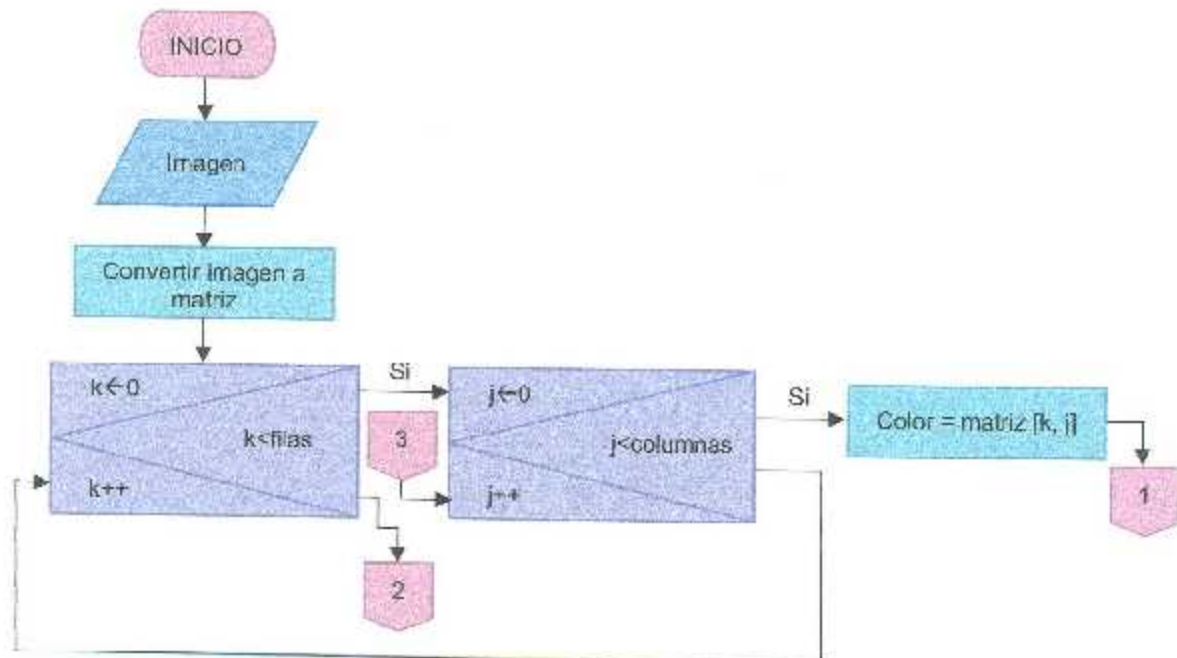
Para convertir la imagen resultante de la aplicación de filtro a una imagen binaria, primero se determina la densidad promedio máxima de toda la imagen para utilizarlo como índice obtener la imagen binaria (Fig. 5.26).

```
int DP_ref = PRGM_DENSIDAD(ima_ref_film.ToBitmap());
int DP_est = PRGM_DENSIDAD(ima_est_film.ToBitmap());

//Imagen binaria
ima_ref = ima_ref_film.Convert<Gray, byte>().ThresholdBinary(new Gray(DP_ref), new Gray(255));
ima_est = ima_est_film.Convert<Gray, byte>().ThresholdBinary(new Gray(DP_est), new Gray(255));
```

Fig. 5.26 Código para obtener las imágenes binarias

A continuación se muestra la representación en Diagrama de Flujo del procedimiento para obtener la Densidad Promedio de la imagen (Fig. 5.27).



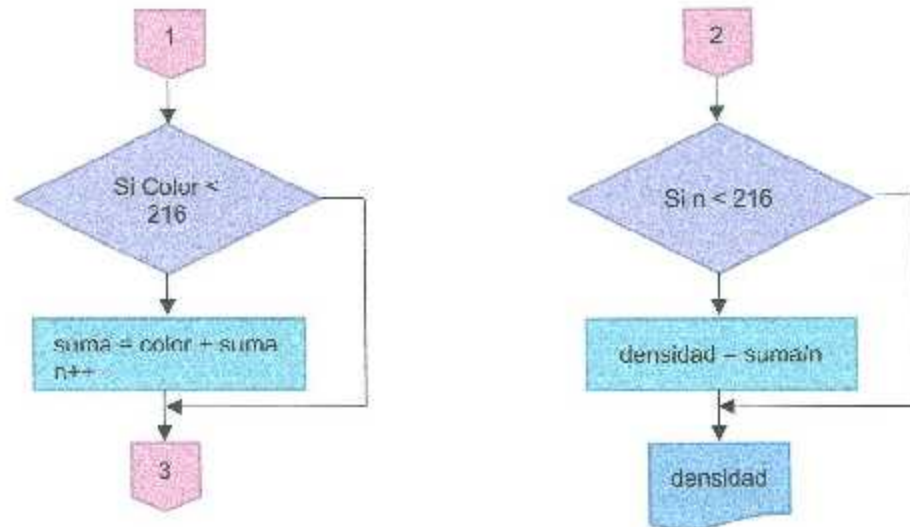


Fig. 5.27 Diagrama de flujo para calcular la densidad máxima promedio de la imagen.

A continuación las imágenes resultantes son sometidas a operaciones morfológicas de erosión y dilatación de la imagen para el cierre de la imagen y así rellenar los espacios vacíos en las áreas de interés. Para eso se dilata la imagen y después se procede a erosionar la imagen (Fig. 5.28).

```

//Cierre
CvInvoke.cvDilate(ima_ref, ima_ref, IntPtr.Zero, 1);
CvInvoke.cvErode(ima_ref, ima_ref, IntPtr.Zero, 1);

CvInvoke.cvDilate(ima_est, ima_est, IntPtr.Zero, 1);
CvInvoke.cvErode(ima_est, ima_est, IntPtr.Zero, 1);
  
```

Fig. 5.28 Cierre de las imágenes.

A continuación se realiza una comparativa entre la imagen de referencia y la imagen a estudiar. Las diferencias encontradas en la comparación son tomadas como áreas de interés y son proyectadas en una nueva imagen (Fig. 5.29); a partir de esa imagen resultante se obtendrán los datos seleccionados para hacer el diagnóstico.

```

Image<Gray, Bgr> Imagen;
Image<Gray, Bgr> Imagen_previa;
Image<Gray, Bgr> Diferencias;
int Threshold = 100;

Imagen_previa = ima_ref;
Imagen = ima_est;

Diferencias = Imagen_previa.AbsDiff(Imagen);
Diferencias = Diferencias.ThresholdBinary(new Gray(Threshold), new Gray(255));
ima_est = Diferencias;
  
```

Fig. 5.29 Código para obtener las diferencias entre las imágenes.



Esta imagen resultante también es sometida a la operación morfológica de cierre, para reducir los espacios vacíos en las áreas, tratando de no alterar mucho la forma del área de otro modo se alteraría el diagnóstico del paciente. No se aplica la operación de Apertura Morfológica para evitar la eliminación de pequeñas áreas que pueden ser posibles anomalías encontradas.

La acción de a continuación (Fig. 5.30) se realiza para detectar los bordes de las áreas encontradas. Esto con el fin de delimitar cada área por separado.

```
//Borde
Gray cannyThreshold = new Gray(150);
Gray cannyThresholdLink = new Gray(120);
Gray circleAccumulatorThreshold = new Gray(120);
Image<Gray, ><>> Borde = ima_est.Canny(cannyThreshold, cannyThresholdLink);
```

Fig. 5.30 Código para la detección de Bordes.

En seguida, por cada borde encontrado se determina el índice de redondez del área (Fig. 5.31), este índice participa en el diagnóstico del paciente.

```
//ENCOTRAR CENTRO
//MOMENTOS momentos;
momentos = contours.GetMoments();
System.Drawing.Point centroid = new System.Drawing.Point((int)(momentos.m00 / momentos.m00), (int)(momentos.m01 / momentos.m00));

//DETERMINAR REDONDEZ
double area_cont = CvInvoke.cvContourArea(contours, false, CV_Structure_32S, false, WholeSeq, 1);
double perimetro = CvInvoke.cvContourPerimeter(contours);
redondez = Math.Abs(Math.Round((4 * area_cont * Math.PI) / (Math.Pow(perimetro, 2)), 1));
```

Fig. 5.31 Código para determinar el índice de redondez de cada área encontrada.

Se determina el plano en donde se ubica cada área encontrada, esto se hace dividiendo la imagen en 3 secciones correspondientes a los 3 planos existentes en una mamografía (Fig. 5.32).

```
//PLANO
double X = r.Left + ((r.Right-r.Left)/2);
if (X > 8 || X < 0)
{
    PLANO = 3;
}
else if (X > 0 || X < 8)
{
    PLANO = 2;
}
else
{
    PLANO = 1;
}
```

Fig. 5.32 Código para identificar el plano correspondiente.



El siguiente paso es determinar la densidad promedio del área con la posible anomalía, esta referencia se toma a partir de la imagen original de estudio pero midiendo solamente el área identificada. El proceso se describe en la Fig. 5.33.

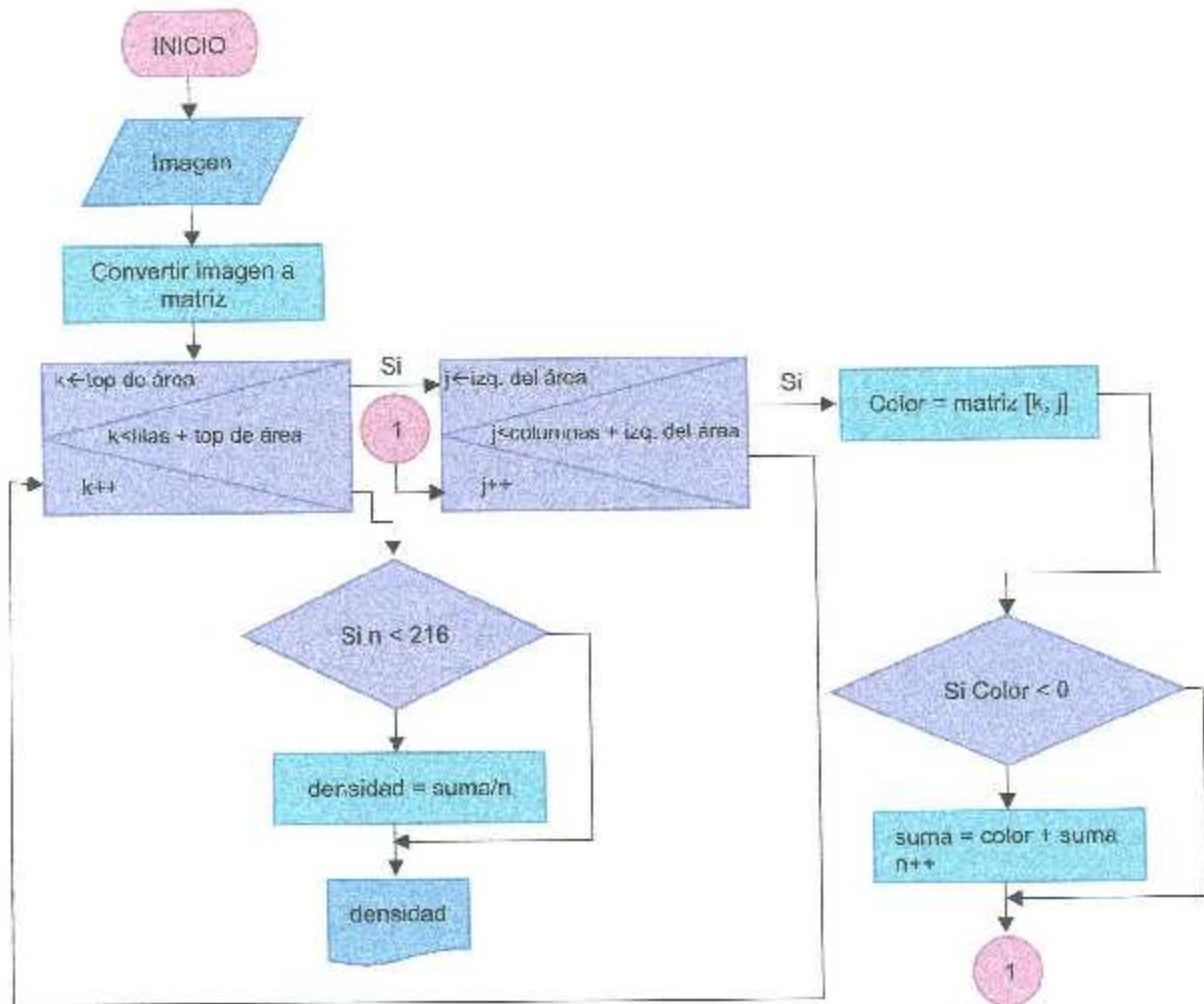


Fig. 5.33 Diagrama de flujo para determinar la densidad promedio del área.

También se calcula el tamaño de la posible anomalía al tomar los píxeles lineales que ocupa el área identificada y convertir esa medida a milímetros (Fig. 5.34).

```

// tamaño
tamaño = Math.Round((Math.Sqrt(Math.Pow(f, 2) + Math.Pow(c, 2))) / 3.77957559, 1);

```

Fig. 5.34 Código para el cálculo del tamaño del área.

Con el objetivo de realizar la primera clasificación, que consta de analizar los resultados obtenidos del procesamiento de imagen y los datos adicionales existentes con el fin de identificar el tipo de posible anomalía existente en la mamografía, se aplica una RNA tipo Backpropagation. A continuación se muestra el modelo de conexión de la RNA utilizada (Fig. 5.35).




Fig. 5.35 Diagrama de la red neuronal artificial utilizada.

Para realizar el entrenamiento de la red se obtienen los datos necesarios de algunas mamografías; se realiza una tabla de contenido donde se especifican los datos muestras obtenidos de cada imagen y el resultado que se espera obtener bajo esas características. Cabe recalcar que cada imagen que se utiliza en la obtención de datos cuenta con un diagnóstico donde describe el tipo de anomalía encontrada en la mamografía, algunas características adicionales, tales como las que se indican en la aplicación, además del tipo de BI-RADS al que pertenece dicho diagnóstico. En seguida se muestra la tabla de resultados con las características obtenidas de las imágenes y del perfil del paciente, y los resultados esperados.

A continuación, en la Tabla 5, se muestra un ejemplo de los datos obtenidos en el proceso para identificar el tipo de anomalía según la mamografía a procesar.

Tabla 5 Tabla de resultados para la identificación de anomalía.

IMAGEN	ENTRADAS: CARACTERÍSTICAS							SALIDAS: ANOMALIAS										
	X1	X2	X3	X4	X5	X6	X7	AN1	AN2	AN3	AN4	AN5	AN6	AN7	AN8	AN9	AN10	AN11
BR4_7	1	0	1	0	0.2	48.5	209	0	0	0	0	0	0	0	1	0	0	0
BR6_1A	2	0	1	1	0.3	21.5	219	0	0	0	0	0	0	0	0	0	0	1

Con la información obtenida en la tabla anterior, se procede a realizar el entrenamiento de la RNA, bajo el algoritmo de aprendizaje del Backpropagation, haciendo uso de la función de transferencia Sigmoidal Logarítmica para determinar la salida y así obtener los pesos ideales y el bias adecuado para tener como resultado la salida esperada.

Al tener los pesos y bias necesarios se procede a traducir el algoritmo a código en C# para ponerlo en marcha en la aplicación.

En primera instancia se definen los valores de entrada de la RNA.

```
public double[] RED_ID_ANOMALIA(int PLANO, int ANTECEDENTE, int BULTO, int MALIGNIDAD, double FORMA, double TAMAÑO, double DENSIDAD)
```

Fig. 5.36 Variable de entrada de la RNA.

Se declaran las matrices de los pesos; tanto para la capa de salida (Fig. 5.38) como para la capa oculta (Fig. 5.39). La RNA utilizada cuenta con una capa de entrada, una capa intermedia oculta y una capa de salida con una sola neurona.

```
//PESOS
double[,] W_OCULTA = { { 0.2961, -1.3970, 4.9617, -1.5339, -1.7236, -0.0877, 0.0415 },
                      { -0.1997, -0.1193, 2.9974, 2.7835, 4.3895, 0.2363, -0.1267 } }
```

Fig. 5.37 Matriz de pesos entre la capa de entrada y la capa intermedia.

```
double[,] W = { { -2.7925, 10.1919, -7.9265 },//1
                { -24.6381, 23.3881, -4.2425 },//2 }
```

Fig. 5.38 Matriz de pesos entre la capa oculta y la capa de salida

Al igual que los pesos, también se cuenta con las matrices de los bias correspondientes a cada capa de la RNA (Fig. 5.39).

```
//BIAS
double[,] BIAS_OCULTA = { { 6.8337, -4.2392, -7.3055 }, //1
                          { 8.6279, -4.7779, 1.1483 }, //2
```

Fig. 5.39 Matriz de bias entre la capa de entrada y la capa intermedia, vector de bias para la capa de salida.

En seguida se muestran las salidas de cada capa de la RNA además del vector de entrada de la red (Fig. 5.40).

```
double[,] Z_OCULTA = { { 0, 0, 0 },
                      { 0, 0, 0 },
                      { 0, 0, 0 } };

double[] Z = { 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0 };
double[] X = { PLANO, ANTECEDENTE, BULTO, MALIGNISIDAD, FORMA, TAMAÑO, DENSIDAD };
```

Fig. 5.40 Entrada y salidas de cada capa de la RNA.

A continuación (Fig. 4.41) se representa el método a seguir para calcular la salida de la RNA.

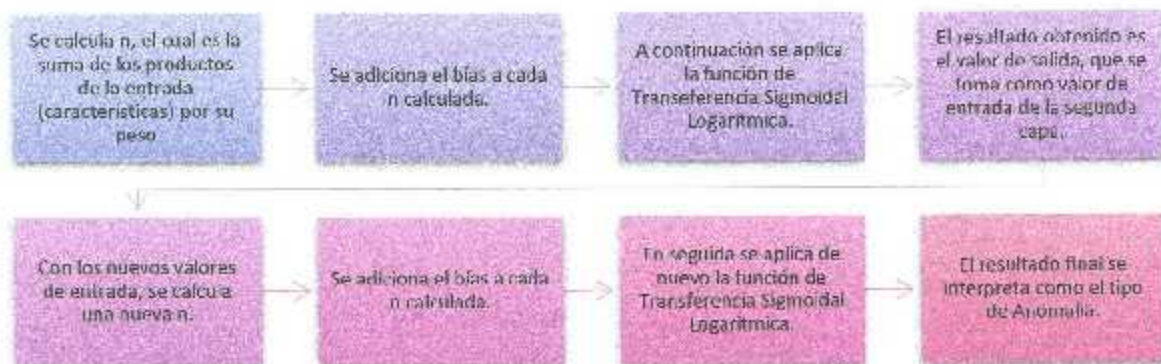


Fig. 5.41 Método para determinar la salida de la RNA.

Donde la salida de la RNA la cual representa el vector de las anomalías presentes en la mamografía además de, ser la entrada de la segunda RNA que permite obtener la categorización BI-RADS correspondiente.

Para la segunda RNA se sigue el mismo procedimiento que la RNA anterior; es una RNA Backpropagation utilizando la función de transferencia Sigmoidal Logarítmica. En esta red también se cuenta con una capa de entrada, una capa intermedia y una capa de salida de una neurona. Para esta se tiene 11 neuronas en la capa de entrada y 3 neuronas en la capa intermedia.

A continuación se muestra el esquema de conexión de la segunda RNA (Fig. 5.42), tomando en cuenta como entrada las 11 posibles anomalías para obtener como salida la categoría BIRADS.

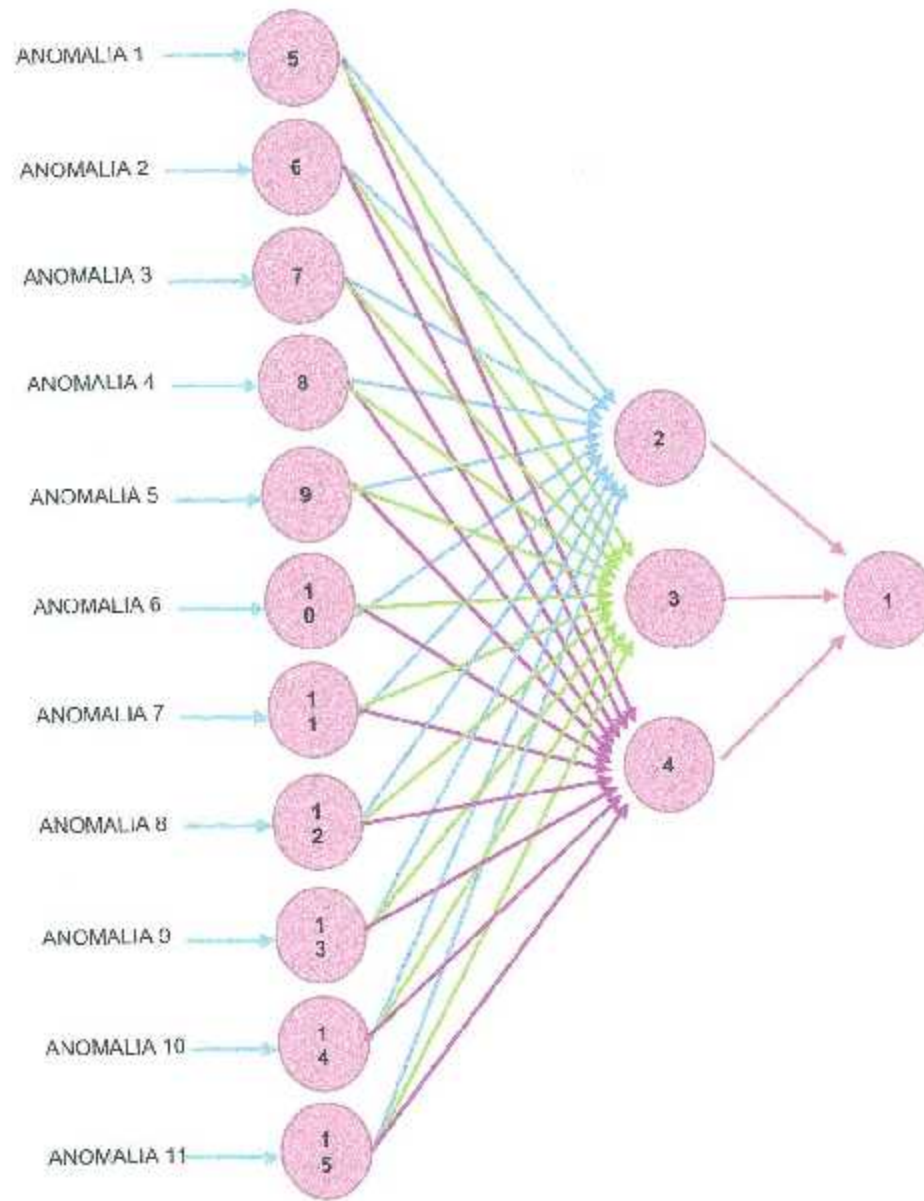


Fig. 5.42 Esquema de conexión de la RNA para la categorización de BIRADS.

También se hace uso de una tabla de contenido donde se relaciona el porcentaje de posibles anomalías obtenidas con la categorización BIRADS descrito en el diagnóstico de las imágenes prueba. Un ejemplo de la relación se muestra en la Tabla 6.

Tabla 6 Tabla de resultados para la categorización BIRADS.

IMAGEN	ENTRADAS: ANOMALIAS											SALIDAS: CATEGORIAS BI- RADS						
	AN 1	AN 2	AN 3	AN 4	AN 5	AN 6	AN 7	AN 8	AN 9	AN 10	AN 11	0	1	2	3	4	5	6
BR4_7	94.3	0	0.4	0.8	1.2	0	0	0.4	0.4	2.4	0	0	0	0	0	1	0	0
BR5_1A	88.2	0	0.7	1.7	1.7	0	0	0	0.3	3.7	3.7	0	0	0	0	0	0	1

Para la segunda RNA, al igual que en la red anterior, se declaran las variables que son la entra de la red como se muestra en la Fig. 5.43.

```
public double[] get_entradas(double AN1, double AN2, double AN3, double AN4, double AN5, double AN6, double AN7, double AN8, double AN9, double AN10, double AN11)
```

Fig. 5.43 Entradas de la RNA para la categorización BIRADS.

Se declaran las matrices y vectores correspondientes a las salidas de cada capa y la entrada de la RNA (Fig. 5.44).

```
double[,] Z_OCULTA = { { 0, 0, 0 },
                       { 0, 0, 0 },
};

double[] Z = { 0, 0, 0, 0, 0, 0, 0 };
double[] X = { AN1, AN2, AN3, AN4, AN5, AN6, AN7, AN8, AN9, AN10, AN11 };
```

Fig. 5.44 Salidas de la RNA y entrada de la misma.

Se declaran las matrices de los pesos; tanto para la capa de salida como para la capa oculta. La RNA utilizada cuenta con una capa de entrada, una capa intermedia oculta y una capa de salida con una sola neurona (Fig. 5.45) y (Fig. 5.46).

```
//PESOS
double[,] H_OCULTA = [
{ 0.0256, -1.0024, 0.9045, -0.7109, -0.5333, -1.4276, 0.0697, -5.4145, -1.6616, -2.7598, -0.9886 },
{ -0.0340, -0.0350, 0.2810, 0.5622, 0.4664, -0.1162, 3.7351, -1.6108, 0.1633, 0.7237, 0.6527 },
];
```

Fig. 5.45 Matriz de pesos entre la capa de entrada y la capa intermedia.



```
double[,] W = { { 19.3201, -0.1630, -4.7459 }, //1
                { -1.1678, 20.5044, -4.7353 }, //2
```

Fig. 5.46 Matriz de pesos entre la capa intermedia y la salida.

Al igual que los pesos, también se cuenta con las matrices de los bias correspondientes a cada capa de la RNA (Fig. 5.47).

```
//BIAS
double[,] BIAS_OCULTA = { { 4.3252, 2.9971, 0.8493 }, //1
                          { 3.5138, 0.5355, -8.2608 }, //2
```

Fig. 5.47 Matriz de bias entre la capa oculta y la intermedia y vector de bias de la capa de salida.

A continuación (Fig. 5.48) se representa el método a seguir para calcular la salida de la RNA.



Fig. 5.48 Método para determinar la salida de la red.

Donde salida de la RNA la cual representa la categoría BIRADS a la que pertenece la mamografía. Este resultado es obtenido a partir del evento de hacer click sobre el botón de Diagnóstico.

Dependiendo del vector de salida es el Radio Button que va a activar (Fig. 5.49).

```

for (int b = 0; b < 7; b++)
{
    switch (b)
    {
        case 0: if (birads[0] == 1) { CAT0.Checked = true; } break;
        case 1: if (birads[1] == 1) { CAT1.Checked = true; } break;
        case 2: if (birads[2] == 1) { CAT2.Checked = true; } break;
        case 3: if (birads[3] == 1) { CAT3.Checked = true; } break;
        case 4: if (birads[4] == 1) { CAT4.Checked = true; } break;
        case 5: if (birads[5] == 1) { CAT5.Checked = true; } break;
        case 6: if (birads[6] == 1) { CAT6.Checked = true; } break;
    }
}

```

Fig. 5.49 Selección de Radio-Button.

Al finalizar de hacer el diagnóstico, la aplicación tiene la opción de guardar los resultados en formato de una imagen. Esta imagen es una captura de la aplicación incluyendo todos los resultados del diagnóstico, datos del paciente y datos adicionales incluidos en el proceso. Para esto se sigue el código propuesto en la Fig. 5.50.

```

private void GUARDARToolStripMenuItem_Click(object sender, EventArgs e)
{
    //string fecha = DateTime.Today.ToShortDateString();
    string fecha = DateTime.Today.Year.ToString() + DateTime.Today.Month.ToString() + DateTime.Today.Day.ToString();

    // Capturar Área de la aplicación.
    Graphics grafic = this.CreateGraphics();
    // tamaño de la capture
    Size gSize = this.Size;
    // Crea Bitmap con el área a capturar. En este caso, con el tamaño de la aplicación
    Bitmap bmp = new Bitmap(gSize.Width, gSize.Height, grafic);
    // un objeto graphics a partir del bitmap
    Graphics grafic2 = Graphics.FromImage(bmp);
    // Copiar el área de la pantalla que ocupa la aplicación.
    grafic2.CopyFromScreen(this.Location.X, this.Location.Y, 0, 0, gSize);

    SaveFileDialog GUARDAR = new SaveFileDialog();
    GUARDAR.InitialDirectory = "Imágenes";
    string ventana = textBox1.Text + "_" + maskedTextBox1.Text + "_" + fecha;
    GUARDAR.FileName = ventana;
    if (GUARDAR.ShowDialog() == DialogResult.OK)
    {
        // Guardarlo como JPG

        bmp.Save(GUARDAR.FileName, System.Drawing.Imaging.ImageFormat.Jpeg);
        // bmp.Save(ventana + ".Jpeg");
    }
}

```

Fig. 5.50 Código para guardar el diagnóstico.

El archivo que se obtiene a través de esta opción es una imagen como la que se muestra a continuación (Fig. 5.51).

Fig. 5.51 Imagen resultante de la opción guardar.

6 Resultados y Conclusiones.


Se realizan pruebas utilizando las mamografías con las que se realizó el entrenamiento de las redes neuronales además de otras imágenes extras. Estas pruebas arrojaron los siguientes resultados mostrados en la Tabla 7.

Tabla 7 Tabla de resultados de pruebas.

IMAGEN		BI-RADS						RESULTADOS		
		0	1	2	3	4	5	6	CORRECTO	INCORRECTO
ESTUDIO	BIRAD0	✓							✓	
	BIRAD1		✓						✓	
	BIRAD1		✓						✓	
	BIRAD2			✓					✓	
	BIRAD2			✓					✓	
	BIRAD2			✓					✓	
	BIRAD2			✓					✓	
	BIRAD3				✓				✓	
	BIRAD3				✓				✓	
	BIRAD4					✓			✓	
	BIRAD4					✓			✓	
	BIRAD4					✓			✓	
	BIRAD5						✓		✓	
	BIRAD5						✓		✓	
	BIRAD5						✓		✓	
	BIRAD6							✓	✓	
BIRAD6							✓	✓		
EXTRAS	BIRAD0		✓							✓
	BIRAD2									✓
	BIRAD2				✓					✓
	BIRAD4				✓					✓
	BIRAD4					✓			✓	
	BIRAD4					✓			✓	
	BIRAD4					✓			✓	
	BIRAD5						✓		✓	
	BIRAD5						✓		✓	
	BIRAD6							✓	✓	
	BIRAD6							✓	✓	
	BIRAD6							✓	✓	

Donde se observa un porcentaje promedio de eficiencia del 86.20% ya que de todas las imágenes utilizadas para realizar el estudio, es decir, el entrenamiento de las redes neuronales artificiales, se obtuvo un 100% de eficiencia mientras que las imágenes que no fueron tomadas en cuenta para hacer el estudio se obtuvo un 66.66%.

Las imágenes utilizadas para realizar el entrenamiento de las redes neuronales artificiales son imágenes con un diagnóstico completo para el caso de la aplicación ADAM, donde indican la edad del paciente, características extras y el tipo de anomalías encontradas en la mamografía, así como la clasificación BIRADS a la que pertenece [28, 29]; así como se muestra en la Fig. 6.1.



BI-RAD 3

Mujer de 50 años con obesidad morbida que acude al médico por notarse una tumoración a la palpación de la mama izquierda. En nuestro caso nos encontramos ante un nódulo bien circunscrito por lo que sería clasificado como BIRADS 3.

Fig. 6.1 Imagen muestra utilizada para realizar el entronamiento de las Redes Neuronales Artificiales.

Se debe de considerar que las imágenes extras utilizadas para la realización de pruebas no presentan un diagnóstico completo como las utilizadas al para el estudio, es decir, no se puede definir los datos adicionales propuestos en la aplicación; además de no presentar anomalías similares a las utilizadas en el estudio; la única clasificación que presentan es la categorización BIRADS a la que pertenece.

De lo anterior se concluye que a pesar de obtener una eficiencia del 86.20% la aplicación resulta de utilidad y satisfactoria debido a su amplia aplicación.

Este tema es muy amplio y para realizar un diagnóstico más riguroso, es de importancia contar con mayor número de muestras de anomalías, e incluso, variaciones de cada anomalía así abarcar cada variante que pueda presentar la mama.

Además de tener una variedad más amplia de muestras es necesario tener un diagnóstico completo considerando todos los factores que presenta el paciente, además de incluir una mayor cantidad de datos adicionales a las ya existentes, como es la edad del paciente, si existen antecedentes de cáncer en la familia, alteraciones en la piel y alteraciones en el pezón además de alteraciones en la forma de la mama, etc. ADAM no considera dichos factores por la falta información de los mismos ya que contar con un diagnóstico tan completo es difícil de obtener. Es por esto que la asesoría de un Médico especialista sería de gran utilidad.



7 Fuentes de información

- [1] I. N. D. E. Y. G. INEGI, "ESTADÍSTICAS A PROPÓSITO DEL... DIA MUNDIAL DE LA LUCHA CONTRA EL CÁNCER DE MAMA," 2015.
- [2] R. S. Tomar, T. Singh, S. Wadhvani, and S. S. Bnadoria, "Analysis of Breast Cancer Using Image Processing Techniques," in *Computer Modeling and Simulation, 2009. EMS '09. Third UKSim European Symposium on*, 2009, pp. 251-256.
- [3] M. H. Z. b. Basim Alhadidi, Hussam N. Suleima, "Mammogram Breast Cancer Image Delection Using Image Processing Functions," *ITJ, IFORMATION TECHNOLOGY JOURNAL*, 2007.
- [4] S. K. Bandyopadhyay, I. K. Maitra, and T. H. Kim, "Identification of Abnormal Masses in Digital Mammography Images," in *Ubiquitous Computing and Multimedia Applications (UCMA), 2011 International Conference on*, 2011, pp. 35-41.
- [5] A. C. Society, "Mammograms and other Breast Imaging Test."
- [6] www.utm.mx, "Análisis de imágenes de mamografía para la detección de cáncer de mama."
- [7] Cancer.Net. (2016). *Mamografía*. Available: <http://www.cancer.net/es/desplazarse-por-alcanci%C3%B3n-del-c%C3%A1ncer/pruebas-y-procedimientos/mamograf%C3%ADa>
- [8] I. M. D. S. S. IMSS, "DIAGNÓSTICO Y TRATAMIENTO DEL CÁNCER DE MAMA EN SEGUNDO Y TERCER NIVEL DE ATENCIÓN."
- [9] leccionesdiagnostico2.wordpress.com. *LECCIONES EN DIAGNÓSTICO POR IMÁGENES*. Available: <https://leccionesdiagnostico2.wordpress.com/bi-rads/birads-mamografico/>
- [10] H. Z. a. R. Smithuis, "Bi-RADS for Mammography and Ultrasound 2013," 2014.
- [11] R. S. C. B. O. d. á. s. d. T. Vilar Bonacasa Eva. *CLASIFICACIÓN BI-RADS*. Available: <http://www.boioncol.com/boletin-26/clasificacion-bi-rads-2.html>
- [12] O. M. Martín, "Procesamiento Digital de Imágenes," Universidad Autónoma de Puebla, Facultad de Ciencias de la Computación 2013.
- [13] <http://catarina.udlap.mx/>, "CAPITULO 2: Procesamiento digital de imagen."



- [14] <http://alojamientos.us.es/>, "Filtros Digitales."
- [15] I. H. F. Gutiérrez. *Polilibro Redes Neuronales Artificiales*. Available: <http://www.hugo-inc.com/RNA/>
- [16] X. B. Olabe, "REDES NEURONALES ARTIFICIALES Y SUS APLICACIONES."
- [17] D. J. Matich, "REDES NEURONALES: CONCEPTOS BÁSICOS Y APLICACIONES." 2001.
- [18] ESCOM, "REDES NEURONALES, Algoritmos de aprendizaje.," ed, 2009.
- [19] A. S. M. Bonifacio Martín del Brío, *REDES NEURONALES Y SISTEMAS BORROSOS*.
- [20] U. N. d. C. Luis Carlos Torres Soler, "EL PERCEPTRÓN, REDES NEURONALES ARTIFICIALES," 2010.
- [21] ESCOM, "RED NEURONAL, Backpropagation," ed, 2009.
- [22] Studylib. *Red Backpropagation*. Available: <http://studylib.es/doc/910025/>
- [23] P. Javier, "DICOM, Almacenamiento y comunicación de imágenes medicas," Hospital General Universitario, Gregorio Marañón.
- [24] G. P. U. d. Deusto, "Estándar y Protocolo de Imágenes Medicas DICOM".
- [25] Microsoft. *Introducción al Visual Studio*. Available: [https://msdn.microsoft.com/es-es/library/fx6bk1f4\(v=vs.100\).aspx](https://msdn.microsoft.com/es-es/library/fx6bk1f4(v=vs.100).aspx)
- [26] <http://www.emgu.com/>. *EMGU CV*. Available: http://www.emgu.com/wiki/index.php/Main_Page
- [27] A. Kirillov. *AForge.Net Framework*. Available: <http://www.aforge.net/framework/>
- [28] U. D. MURCIA. (2013/2014). *Proyecto Base Interactiva de Radiodiagnóstico* Available: <http://proyectobird.es/edicion9/mm.htm>
- [29] U. D. MURCIA. (2011/2012). *Proyecto Base Interactiva de Radiodagnóstico*. Available: <http://www.proyectobird.es/edicion%206/mm.htm>

