

| UNIVERSIDAD SEÑOR DE SIPÁN

**FACULTAD DE INGENIERÍA, ARQUITECTURA Y
URBANISMO**

**ESCUELA PROFESIONAL DE INGENIERÍA DE
SISTEMAS**

TESIS

**“UTILIZACIÓN DE ALGORITMOS PARA LA
IDENTIFICACIÓN AUTOMÁTICA DE
MICROCALCIFICACIONES EN IMÁGENES
DIGITALES DE MAMOGRAFÍA”**

**PARA OPTAR EL TÍTULO PROFESIONAL DE
INGENIERO DE SISTEMAS**

Autor:

Bach. Raul Quesquen Liza

Asesor:

Dr. Mario Ramos Moscol

Línea de Investigación:

Infraestructura, Tecnología y Medio Ambiente

Pimentel, Perú

2020



Dedicatoria

Quiero dedicar este proyecto en primer lugar a Dios, luego a mis padres que en vida fueron Leonor Liza M. y Eleodoro Quesquén A. quienes hubieran estado orgullosos de los logros que he conseguido, después a mi esposa y a mis hijos quienes dudaron en un comienzo que este proyecto se haga realidad pero que con mi dedicación y perseverancia les he demostrado que con trabajo y estudio se llega lejos.

Agradecimiento

Deseo agradecer a muchas personas que me apoyaron en este proyecto de estudios:

Al Ing. Lucio Martínez, gerente de Electrónica Biomédica Martínez, empresa con la actualmente trabajo y también al Sr. Roberto Segura Carrera, gerente de la empresa X-ray Service, por sus desinteresados apoyos en bien de mi desarrollo personal y profesional.

Al Ing. Víctor Bazán Calderón, al Ing. Manuel Burga Maldonado, al Ing. Jesús Raúl Quesquen Esquen, Ingenieros residentes del Grupo A, dedicado al mantenimiento de equipos biomédicos de diagnóstico por imágenes del Hospital Nacional Almanzor Aguinaga Asenjo y al supervisor Técnico Wilmer Mayanga Juárez, del área de mantenimiento de equipos de Imagenología, por su apoyo durante todo el curso de mis estudios hasta la fecha actual.

A mi esposa, mis hijos, mis compañeros de trabajo, a mis profesores y asesores de tesis.

Resumen

En la investigación de tesis realizada he utilizado técnicas y algoritmos de tratamiento digital de imágenes e inteligencia artificial para finalmente identificar, reconocer microcalcificaciones, que son anomalías o lesiones patológicas que pueden aparecer en imágenes digitales de mamografía y quienes son signos tempranos del cáncer de mamas. Para tal objetivo se ha desarrollado un modelo que logra identificar, reconocer microcalcificaciones, que pueden aparecer dentro de las imágenes digitales de mamografías, obtenidas en hospitales de Essalud. Dicho modelo está basado en técnicas y algoritmos de tratamiento digital de imagen y de reconocimiento de patrones utilizando una red neuronal, y que han demostrado ser más eficaces en la experimentación desarrollada en esta investigación.

Palabras clave:

Detección y diagnóstico asistido por computadora (CAD y CADx), Tratamiento y análisis de imágenes mamográficas, Segmentación y reconocimiento de patrones, Región de interés (ROI), Redes neuronales artificiales (RNA), Microcalcificaciones y masas tumorales, Sensibilidad y especificidad.



Abstract

In the thesis research I have used techniques and algorithms for digital imaging and artificial intelligence to finally identify, recognize microcalcifications, which are abnormalities or pathological lesions that may appear on digital mammography images and who are early signs of breast cancer. To this end, a model has been developed that identifies, recognizes microcalcifications in regions of interest extracted from digital images of mammograms obtains in Essalud hospitals. This model is based on techniques and algorithms of digital image treatment and pattern recognition using a neural network, and which have proven to be more effective in the experimentation developed in this research.

Keywords

Computer-assisted detection and diagnosis (CAD and CADx), Treatment and analysis of mammographic images, Segmentation and pattern recognition, Region of interest (ROI), Artificial neural networks (RNA), Microcalcifications and tumor masses, Sensitivity and specificity.



Índice

I. INTRODUCCION	12
1.1. Realidad Problemática.....	12
1.1.1 . A nivel internacional	12
1.1.2. A nivel Nacional.....	13
1.1.3. A nivel Institucional	14
1.2. Antecedentes de Estudios	14
1.2.1. A nivel Nacional.....	14
1.2.2. A nivel Internacional	16
1.3. Teorías relacionadas al tema.....	18
1.3.1.-Valores continuos (analógico) contra discretos (digital)	18
1.3.2.- La Imagen Digital	19
1.3.3.- Relaciones Básicas entre Pixeles.....	23
1.3.3.2.-Conectividad	24
1.3.4.-Análisis teórico de técnicas y algoritmos utilizados	24
1.3.5. -Sistema de Base de Datos e Informes de Imágenes del Seno (BI-RADS)	43
1.3.6.- Extracción de características del objeto microcalcificación	46
1.4. Formulación del Problema	50
1.5. Justificación e Importancia de la Investigación	50
1.5.1. Científica	50
1.5.2. Institucional.....	50
1.6. Hipótesis.....	51
1.7. Objetivos de la Investigación	51
1.7.1. Objetivo general	51
1.7.2. Objetivos específicos.....	51
II. MATERIAL Y METODO.....	52
2.1. Tipo y Diseño de Investigación	52
2.1.1 Tipo de investigación	52
2.1.2 Diseño de la investigación.....	52
2.2. Población y Muestra	52



2.3. Variables, Operacionalización	52
2.3.1. Variable Independiente	52
2.3.2. Variable Dependiente	53
2.4. Técnicas e instrumentos de recolección de datos, validez y confiabilidad	54
2.4.1. La media aritmética y la desviación estándar	55
2.4.2. Métricas de uso común para comparar la calidad entre dos imágenes luego de un proceso de restauración: MSE (Error Cuadrático Medio) y PSNR (Peak Signal to noise Ratio).....	55
2.4.3. Métrica para la evaluación del realce de contraste(CII)	56
2.4.4. Evaluación del desempeño del clasificador (sensibilidad y especificidad)	56
2.5.. Procedimientos de análisis de datos.....	58
2.6. Criterios éticos	58
2.7. Criterios de rigor científico.....	60
III. RESULTADOS.....	61
3.1.-Resultados y análisis en tablas y figuras	61
3.2..Modelo utilizado para llegar a los resultados.....	71
3.2.-Realización de la metodología propuesta para la investigación.....	73
3.2.1.-Utilización de diferentes técnicas y algoritmos de filtrado, así como métricas para evaluar la efectividad de estas, eligiéndose el más eficiente	73
3.2.2.-Utilización de diferentes técnicas y algoritmos de realce de contraste, así como métricas para evaluar la efectividad de estas, eligiéndose el más eficiente	75
3.2.3.-Implementación de la transformada tophat como una subsegmentación para identificar las microcalcificaciones dentro de la imagen digital mamográfica.....	77
3.2.4.-Resultados en la segmentación utilizando técnicas de umbralización	80
3.2.5.-Resultados experimentales utilizando la imagen del Phantom como patrón para encontrar el área mínima posible de las microcalcificaciones	80
3.2.6. Etapa de clasificación a base de una red neuronal	88
3.2.7. Entrenamiento de la red neuronal como elemento clasificador de microcalcificaciones	88
3.2.8. Prueba de la red neuronal como elemento clasificador de microcalcificaciones	94
IV. CONCLUSIONES Y RECOMENDACIONES	99



4.1. Conclusiones	99
4.2. Recomendaciones	101
REFERENCIAS	103
ANEXOS	105



Indice de figuras

Figura 1. Valores continuos analógicos contra discretos digitales.18

Figura 2 .Representación matricial en pixeles de una imagen digital.21

Figura 3. (a) Imagen a color y sus tres componentes RGB, (b) Imagen en escala de grises22

Figura 4. Pixeles vecinos de un pixel:(a) Cuatro vecinosN4 (p), (b) Ocho vecinosN8 (p).23

Figura 5. Clasificación del vecindario de un pixel según el orden.24

Figura 6. Operación de convolucion de una señal unidimensional25

Figura 7. Señal triangular resultado de la convolucion después de interaccionar dos señales rectangulares.25

Figura 8.. La matriz de convolucion, en este caso de 3x3 recorre la imagen interactuando con los pixeles de la imagen produciendo una imagen convolucionada.26

Figura 9. Pixeles que intervienen en el filtrado espacial por convolucion de la imagen con la máscara o núcleo de convolucion.27

Figura 10. Respuesta en frecuencia y tiempo de un filtro paso-bajo.....28

Figura 11. Respuesta en frecuencia y tiempo de un filtro paso-alto29

Figura 12. Respuesta de la derivada ante un borde de la imagen30

Figura 13.. Ilustración de la primera y segunda derivada de una función digital unidimensional representándolo en una sección de un perfil de línea de intensidad horizontal.31

Figura 14. Perfil de línea mostrando la respuesta de la derivada a los cambios de niveles de gris(a) de una radiografía de tobillo y (b) de una mamografía32

Figura 15. Histogramas de una mamografía ideal.35

Figura 16. Curvas de transferencia para la correccion gamma37

Figura 17. Neurona Biológica39

Figura 18. El paso de la información sucede gracias a la sinapsis, que son conexiones entre neuronas, sucediendo así el paso de la información de una neurona a otra, y entonces la intensidad o la fuerza de estas conexiones se le llama peso sináptico.40

Figura 19. Después de procesos de multiplicación, suma y activación la señal llega a otras neuronas.40

Figura 20. Modelo matemático de una neurona.....40

Figura 21. Funciones de activación aplicadas en las RNA.(a)Identidad.(b)Escalon.(c)Lineal Saturada.(d)Sigmoidal.(e)Tangente Hiperbólica.(f)Gaussiana.42

Figura 22. Clasificación de las microcalcificaciones según un patrón de distribución46

Figura 23. El perímetro de un objeto se puede definir como la cantidad de pixeles del contorno48

Figura 24. Circularidad o relación área-perímetro para diferentes formas.....49

Figura 25. Matriz de confusión en el desempeño del sistema57

Figura 26. Grafica de comparación de las diferentes técnicas de filtrado experimentadas.61

Figura 27. Grafica de comparación de las diferentes técnicas de realce de contraste experimentadas.....63

Figura 28. (a) y (b): Resultado después de recortar, procesar y segmentar la imagen de entrada, quedando aisladas totalmente las microcalcificaciones.65

Figura 29. Imagen final segmentada con parámetros de mejor respuesta.66

Figura 30. Error del 2% que alcanzo la red entrenada en un comienzo.67

Figura 31. Error del 1% que alcanzo finalmente la red neuronal68

Figura 32. Resultado del clasificador con data set de prueba.68



Figura 33. Curva ROC obtenida después de pasar la data set de prueba	69
Figura 34. Area bajo la curva del clasificador neuronal (AUC).	70
Figura 35. Modelo de la propuesta de investigación	71
Figura 36. Imágenes con filtro box (kernel de 5x5) o de media, filtro Gaussiano, filtro de la mediana, filtro gradiente y filtro laplaciano.....	75
Figura 37. Imagen procesada con 3 diferentes técnicas de realce de contraste	77
Figura 38. Aplicación de la transformada tophat a una imagen mamográfica con 2 diferentes elementos estructurantes.	78
Figura 39.(a) Elemento estructural no lineal ‘ball-shaped’ (elipsoide) y (b) su curva no lineal de reforzamiento	79
Figura 40. Elemento estructural ball shaped definido por Matlab	79
Figura 41. Phantom o maniquí (utilizado para control de calidad de equipos de mamografía), utilizándolo en esta investigación como imagen patrón para encontrar el área mínima posible de las microcalcificaciones	80
Figura 42. (a) El phantom contiene: 6 fibrillas de nylon, 5 grupos de microcalcificaciones y 5 masas. Sus dimensiones (L/W/h): 10.2x10.8x4.5 cm. (b) Imagen obtenida del phantom.....	81
Figura 43. Resultado inicial para hallar el área mínima detectable de la microcalcificaciones utilizando la imagen del phantom (de detectan microcalcificaciones en el grupo 7 y 8 de 0.52 y 0.4 mm).....	83
Figura 44. El sistema logra detectar 3 grupos: Un grupo de 0.54 mm(6/6), otro de 0.4(6/6) y dos microcalcificaciones del grupo de 0.32mm(2/6).	84
Figura 45. Red Neuronal que recibe los 39 descriptores de forma-localización y de intensidad, en sus neuronas de entrada y que clasificara las microcalcificaciones en benignos (0) o sospechosos (1).	88



Indice de tablas

Tabla 1. Mascaras utilizadas para aplicar la derivada de 1er orden	33
Tabla 2. Mascara utilizada para aplicar la 2da derivada el laplaciano	33
Tabla 3. Otras mascararas para implementar el laplaciano	34
Tabla 4.-Clasificación segun categorias de la lesión cancerígena en las mamas.	44
Tabla 5.-Clasificación de las microcalcificaciones según su morfología.....	45
Tabla 6.-Operacionalización de la variable independiente	53
Tabla 7.-Operacionalización de la variable dependiente	54
Tabla 8.-Valores de la relación señal-ruido con diferentes técnicas de filtrado	61
Tabla 9.-Valores del índice de mejoramiento de contraste con diferentes técnicas	62
Tabla 10. Llenado de datos con la matriz confusión.....	69
Tabla 11. Dataset etiquetado de imagenes digitales mamográficas construido para el entrenamiento del clasificador neuronal con neuroph estudio.	89
Tabla 12. Tabla que resume los experimentos para el entrenamiento de la red neuronal con Framework Neuroph Studio.	94
Tabla 13. Dataset etiquetado de images digitaltes mamográficas construido para el test del clasificador neuronal.	95

I. INTRODUCCION

En la primera parte de este trabajo de investigación he realizado un tratamiento digital de la imagen mamográfica, para lograr buena calidad de imagen, libre de artefactos, ruido aleatorio y con una buena calidad de contraste. Para tal objetivo he utilizado técnicas y algoritmos de reducción de área, reducción de ruido y técnicas de reforzamiento de contraste, y con ello lograr obtener buenos resultados en la etapa final de clasificación e identificación de las microcalcificaciones.

Luego continuamos con la segmentación, la cual consiste en identificar y aislar cada uno de los objetos o elementos presentes en la escena, en nuestro caso la detección de microcalcificaciones, y se realiza utilizando técnicas de morfología matemática y de umbralización por el método de Otsu.

La siguiente etapa es la descripción y extracción de características, acá se extrae información cuantitativa. Se obtiene el vector de características o descriptores del objeto microcalcificación.

Finalmente el clasificador que reconoce los patrones o descriptores de las microcalcificaciones, es una red neuronal quien determina si son normales (benignos) o sospechosos (malignos).

1.1. Realidad Problemática

Alvarez, Guevara & Holguín. (2014), teniendo en cuenta que nos dicen que al presentarse ciertas dificultades al diagnosticar el cáncer de seno mediante imágenes mamográficas, y no existiendo a la fecha un conjunto de técnicas y algoritmos con los cuales se pueda obtener una identificación automática con certeza en el hallazgo de microcalcificaciones tanto como para descartar y detección temprana del cáncer de mamas. Me propuse en esta investigación utilizar técnicas algorítmicas para la identificación automática de microcalcificaciones en imágenes digitales de mamografías, cumpliendo con los objetivos ante la complejidad del tema.

1.1.1 . A nivel internacional

Cerrato & Quintanilla (2014), nos informan que el cáncer de seno, es el de mayor frecuencia y causa de muerte en las mujeres. También resaltaron que es la mamografía la forma más eficaz para mostrar patologías mamarias, contribuyendo a la detección temprana del cáncer de seno para aplicar un tratamiento a tiempo para la curación. Las microcalcificaciones pueden aparecer en la imagen mamográfica como



primeros signos patológicos y que al ser pequeños depósitos de calcio aparecen como puntos brillantes. Se considera que entre el 30 y 50% de diagnósticos de cáncer de seno a nivel mundial, ha sido por que se han detectado microcalcificaciones. También resaltan que cuando se observan las mamografías, esta se vuelve tediosa y fatigante para el radiólogo, pues se analiza factores como el tamaño, forma y bajo contraste, considerando que el factor subjetivo también influye. Por lo que se han desarrollado sistemas de apoyo basados en computadora, mejorando las condiciones de visualización de las imágenes y otros que detectan automáticamente la patología actuando como una segunda opinión.

Estos sistemas tienden a mejorar la sensibilidad y especificidad. A partir de aquí es este trabajo intenta desarrollar un método para finalmente detectar e identificar las microcalcificaciones que aparecen en zonas de interés, para con ello contribuir con la detección precoz del cáncer de seno. También ofrecer una herramienta computacional que brinde una opinión objetiva y descriptiva de las microcalcificaciones gracias a esta herramienta computacional.

1.1.2. A nivel Nacional

Según la investigación de Cajusol (2019), en los últimos años se están sumando avances tecnológicos con la finalidad de mejorar la sensibilidad y especificidad de la mastografía en la detección del cáncer de seno, por lo que se están desarrollando e introduciendo sistemas de ayuda al diagnóstico (CAD), que son programas de computadora diseñados para detectar opacidades o microcalcificaciones anormales en una mamografía; sin embargo, aún no se ha demostrado concluyentemente su eficiencia y su aplicación aún no se ha difundido. Adicionalmente, han surgido otras alternativas a las técnicas rutinarias y que, adicionalmente, han traído consigo nuevos desafíos. Desde hace poco tiempo existen equipos digitales que realizan estudios tomográficos de las mamas, a los que se les denomina Tomosíntesis, los cuales son mamógrafos especiales que en vez de tomar 2 imágenes de cada mama, su tubo de rayos X gira aproximadamente ± 15 grados (últimamente ± 25 grados en equipos Siemens) alrededor de este órgano, obteniendo varias imágenes desde diferentes ángulos, para de esa forma, observar una misma estructura de la mama desde diferentes perspectivas, para discriminar mejor las estructuras patológicas de las normales.



1.1.3. A nivel Institucional

A la fecha 2019 a nivel institucional en el hospital de Essalud (Almanzor Aguinaga Asenjo), se tiene la opción de mamografía con CR (radiografía computarizada). El digitalizador al tener la opción de procesar mamografías, se obtiene entonces imágenes digitales en formato DICOM y JPEG. Otra tecnología que está vigente actualmente es latomosíntesis del seno, que generan mamografías tridimensionales o varias imágenes de cada mama en cortes milimétricos. La introducción de esta tecnología sería una gran ayuda en la investigaciones, pues obtendría imágenes digitales con mayor resolución y con otros formatos digitales de bajas perdidas de compresión, ya que las microcalcificaciones motivo de estudio son de tamaño submilimétricas, y también tendría la opción de introducir estas herramientas computacionales con la finalidad de combinar tecnología hardware de punta con software de detección y diagnóstico.

1.2. Antecedentes de Estudios

Según Carrillo (2009), desarrolló modelos de detección (CAD) y diagnóstico (CADx) asistido por computadora para el análisis con el reforzamiento de la calidad de imagen, pues en los nuevos equipos biomédicos electrónicos se están incluyendo estas herramientas de software.

En los antecedentes de investigación presentados son varios trabajos que se han realizado sobre el tema, así como métodos, técnicas, y algoritmos que utilizaron para analizar la imagen mamográfica, su naturaleza y características de los objetos o patrones a detectar. Las ideas principales que se manejan en la mayoría es considerar una etapa de extracción de características, diversos clasificadores y aplicar un método de evaluación de clasificadores. Este análisis es muy importante porque permite que el desarrollo de este trabajo de tesis este en un entorno totalmente actualizado, considerando lo más reciente del estado del arte. Con esto se busca que el trabajo realizado compare y seleccione técnicas y algoritmos, que mejoren o actualicen este campo de investigación.

1.2.1. A nivel Nacional

Alvarez, Juan. (2014), realiza un trabajo de investigación llamado: “Sistema de detección de cáncer de mama en mujeres, mediante el uso de redes neuronales”, de la Universidad del Altiplano Puno. Realizó una investigación en imágenes mamograficas



digitales en tiempo real, con la finalidad de que el sistema automáticamente diagnostique a pacientes con cáncer. Utilizó patrones de red neuronal para su aprendizaje seleccionando los parámetros de red como el número de capas y neuronas y factor de aprendizaje. Luego de haber realizado el test a la red entrenada, clasificó la mamografía procesada y lanzó resultado de malignidad o benignidad, por ende la herramienta computacional ayudó al médico especialista y al paciente en un prediagnóstico.

Gavidia, Carlos. (2014), en su tesis de maestría: “Segmentación de imágenes médicas mediante algoritmos de colonia de hormigas”, de la Pontificia Universidad Católica del Perú, logró una eficiente segmentación o extracción de segmentos correspondientes a la materia gris, materia blanca y líquido cefalorraquídeo de imágenes de resonancia magnética. Para tal finalidad utilizó un método metaheurístico de algoritmos de colonia de hormigas artificiales, que imitan el comportamiento de la hormigas cuando buscan su alimento y el nido, realizando tareas específicas de procesamiento de imágenes. El resultado final fue una segmentación superior a los algoritmos tradicionales actualmente existentes.

Segura del Río, Cesar. (2014), en su proyecto de tesis: “Propuesta de técnica para la estimación de densidad mamaria en mamografías digitales utilizando técnicas de segmentación y estimadores globales”, de la Pontificia Universidad Católica del Perú, comparó el tejido denso mediante técnicas de segmentación proponiendo un algoritmo a base de estimadores globales. Entre las técnicas de segmentación que experimentó se menciona a la segmentación de Bden, bimodal, C-medias difusas y Otsu, demostrando un mayor grado de correlación con el tejido denso calculado por el médico radiólogo especialista. Encontrándose estimadores globales de intersección sobre unión y SSIM, la segmentación propuesta da mejores resultados en comparación con las segmentaciones de Bden, bimodal, C-medias y Otsu. Además demostró que el coeficiente de Pearson dió mejores resultados para indicar el grado de correlación que existe entre los porcentajes de tejido denso estimado por el especialista, la técnica propuesta y demás técnicas experimentadas.

Limache, Roxana (2016), en su tema de investigación: “Un enfoque híbrido para la clasificación de imágenes de Resonancia Magnética del Cerebro”, de la Universidad Nacional de San Agustín de Arequipa, mejoró el diagnóstico médico utilizando



sistemas de diagnóstico asistido por computador (CAD). Estos sistemas detectaron zonas sospechosas que contienen alguna lesión. Esto ayudaría al radiólogo a interpretar con menor dificultad la información clínica contenida en la imagen. En el estudio se propuso una técnica híbrida formada por una red neuronal y un algoritmo genético para detectar en una imagen de resonancia magnética del cerebro si tiene signos anómalos. En la etapa de clasificación se usa una red neuronal (MLP, perceptrón multicapa) con un algoritmo genético donde finalmente hay resultados prometedores.

Cajusol, Juan & Céspedes, Juan. (2019), cuyo título de su proyecto de tesis es: “Procesamiento digital y transmisión de imágenes radiográficas para ayudar en el diagnóstico y tratamiento oportuno de enfermedades pulmonares en localidades rurales de Lambayeque”, de la Universidad Nacional Pedro Ruiz Gallo, desarrollaron un modelo de procesamiento digital, comprensión y transmisión de imágenes radiográficas en tiempo real y sin demora, para que los especialistas puedan diagnosticar y tratar oportunamente enfermedades pulmonares en localidades rurales de Lambayeque. Se realizó procesamiento de la imagen radiográfica para su comprensión de datos y la optimización del canal de transmisión (señal móvil zonal). Apoyándose del proceso de comprensión JPEG y la transformada de Walsh-Hadamard, especial para comprensiones de imágenes médicas. Esto mejoró los niveles de recepción de señal móvil en un equipo celular, con el fin de mejorar en lo más posible la modulación y con ello la tasa de bits o transferencia de datos.

1.2.2. A nivel Internacional

Hugo, Restrepa & José, Padilla (2013), en su cita de estudio: “Reconocimiento de patrones de imagen en mamografías”, usaron la metodología empleada por la comunidad científica, considerando etapas de procesamiento, segmentación, agrupamiento y clasificación. Implementaron y optimizaron algoritmos, permitiendo el reconocimiento de patrones de microcalcificaciones para la detección temprana del cáncer de mama. Los algoritmos obtenidos, identificaron anomalías en las mamografías. En el preprocesamiento realizó la eliminación de la etiqueta de las imágenes y se logró reducir el área de trabajo limitando las imágenes solo a zona de interés mediante criterios de conectividad de píxeles y el etiquetado de componentes conexas, además se realizó la reducción de ruido y el realce de contraste. En la



segmentación de microcalcificaciones individuales utilizó wavelets para su posterior agrupamiento por medio del cálculo de comparación de distancia. En la validación de los algoritmos, se utilizaron imágenes de una base de datos.

Joana, Claudia & Moya, Santamaría. (2014), el tema que abordan es la: “Construcción de una base de datos de imágenes de mamografía para la identificación de microcalcificaciones”, de la Universidad Tecnológica de Pereira, diseñaron una base de datos, analizaron fases de almacenamiento, validación médica y etiquetado de las imágenes. Se realizó un procesamiento para eliminar artefactos derivados de la adquisición, seguido de un análisis de textura fractal y patrones locales binarios. La metodología reportó la identificación de microcalcificaciones, basada en descriptores de textura, y que se evidencian en la información guardada en la base de datos en un porcentaje de acierto del 93.2%. Los resultados evidenciaron que el método de análisis de textura fractal es mejor que el método de patrones binarios en la extracción de características en una determinada área de la imagen con presencia de microcalcificaciones.

Díaz, S. Oporto. (2014), en su publicación: “Clasificación de imágenes de mamografías según el tipo de tejido predominante usando redes neuronales artificiales”, del Centro de Sistemas Inteligentes, Instituto Tecnológico de Monterrey-México, clasificó las imágenes en función al tipo de tejido, usando dos métodos de extracción de características, primero calculó parámetros en 16 pequeñas ventanas. Luego utilizó el histograma de cada imagen; clasificando del tipo de tejido de la mama: adiposo, fibroglandular y denso, es un paso previo para identificar masas mamográficas sospechosas de malignidad. El método del histograma ofreció mejores resultados en promedio que el basado en parámetros pero sin embargo el mejor resultado entre los grupos de entrenamiento de prueba fue mayor para el método basado en parámetros.

Lizcano, J. Avelino. (2015) en su tema de estudio: “Sistemas de ayuda al diagnóstico y reconocimiento de microcalcificaciones en mamografía mediante descriptores de escala y redes jerárquicas”, de la Universidad Politécnica de Madrid-España, estudió métodos teóricos para implementar herramientas computacionales de análisis de imágenes digitales específicamente en la identificación y clasificación de

microcalcificaciones. Analizó técnicas de morfología matemática, máquinas de vectores de soporte y redes neuronales convolucionales, teniendo en cuenta en el diseño los descriptores de escala y jerarquía de las capas de red.

Pérez, M. Gabriela. & Fiallos, C. Bolívar (2015), en su tema de investigación: “Detección automática de lesiones en mamografías usando técnicas de análisis de imágenes”, de la Universidad Técnica de Ambato-Ecuador, mostraron una forma de reconocer patologías mamarias presentes en imágenes digitales extrayendo automáticamente las características que describen las posibles asimetrías cuando se compararon la mama derecha y la izquierda. Logró eliminar de estas imágenes el ruido, y segmenta adecuadamente la imagen para que ayuden en la aparición de posibles asimetrías que reflejan las lesiones patológicas que se busca.

1.3. Teorías relacionadas al tema

1.3.1.-Valores continuos (analógico) contra discretos (digital)

En un valor continuo no hay puntos vacíos, todo instante tiene un valor, se tiene infinitos valores, por lo que se usan los números reales, que incluyen los naturales, racionales e irracionales.

Es por eso que muchas veces para facilitar los cálculos al trabajar con valores continuos tendemos a “discretizarlos” usando números naturales o enteros.

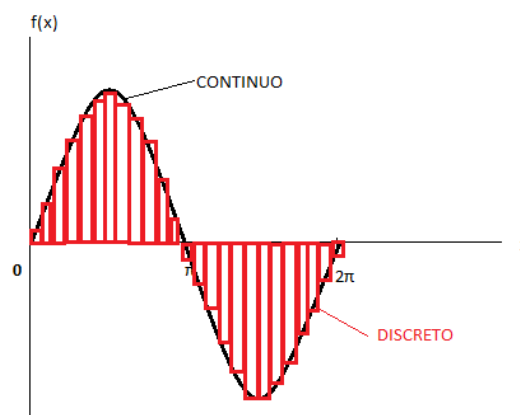


Figura 1. Valores continuos analógicos contra discretos digitales.



El cálculo del área de la región para el caso de una señal continua, utiliza la siguiente ecuación:

$$\text{Area} = \int_0^t f(x) dx \quad (\text{caso continuo})$$

Del mismo modo el cálculo del área de la región para el caso de una señal discreta, utiliza la siguiente ecuación:

$$\text{Area} = \sum_0^t f(x)x \quad (\text{caso discreto})$$

Cuando se digitaliza una imagen hablamos de una discretización o cuantización, sucediendo dos procesos el muestreo (sampling) y la cuantización (quantization). Los datos continuos o reales son tomados como enteros, pasan por un convertidor analógico-digital, provocando pérdidas de precisión en la información. Entonces para generar una imagen se usan formatos relacionados con número de bits tal que por ejemplo con una profundidad de 8 bits se logran pixeles con 256 niveles de gris (de 0 a 255). A partir de esto se puede hablar de una resolución radiométrica como el número de bits por pixeles en una imagen.

1.3.2.- La Imagen Digital

Imagen viene del latín “imago” (retrato) y del verbo “imitari” o etimológicamente “imitación de la realidad”, algo que imita o captura el entorno en que vivimos.

Otra definición de imagen es que es una muestra pictórica de una escena y que tiene información descriptiva de la misma.

Una definición matemática es que la imagen digital puede ser considerada como una función bidimensional $f(x, y)$.

Si el dominio, valores de (x, y) y el rango, valores de $f(x, y)$ son continuos (conjunto de los números reales, que incluyen los naturales, racionales e irracionales), la imagen es continua o análoga; si el dominio y el rango son discretos (usando números naturales o enteros) la imagen es digital, considerando entonces a la imagen digital como una matriz de números.

Luego una imagen digital se puede representar como función, matriz o conjunto.



1.3.2.1.-Imágenes como Funciones

Una imagen puede ser representada por una función en dos dimensiones $f(x, y)$, en un espacio de coordenadas (x, y) . En el caso de una imagen monocromática el valor de $f(x, y)$ se le denomina nivel de gris en el punto de coordenadas (x, y) .

Una imagen (I) también se puede representar como una función vectorial, que va a mapear la posición del pixel (pi) en la rejilla bidimensional (G^2) de modo que el elemento de la imagen (e_i) cumple que: $e_i \in I \Leftrightarrow e_i = \{pi, f(pi)\}$.

La imagen digital está definida como una función cuyo dominio (D_f) es el conjunto de pixeles de la misma, incluido en rejilla bidimensional (Z^2), y definida directamente en una rejilla tridimensional (R^3).

$$f: D_f \subset Z^2 \Rightarrow R^3$$

Esto implica, que al combinar la información de tres canales RGB se define unívocamente el color de un pixel y también la escala de grises queda definida con una parte de esta información.

1.3.2.2.-Imágenes como Matrices

Una imagen digital puede representarse como una matriz en una rejilla de dos dimensiones cuyo índice filas y columnas corresponden a un pixelo elemento en la imagen y el valor del correspondiente elemento de la matriz indica el nivel de gris, color o brillo de un punto.

Para cada posición fila-columna tiene un valor particular que es el valor del pixel.

-Caso particular $d = 2$ (espacio bidimensional)

$$X = X_0 \cdot X_1$$

con:

$$X_0 = \{0, 1, \dots, r - 1\} \text{ y } X_1 = \{0, 1, \dots, c - 1\} \text{ donde } r(\text{filas}) \text{ y } c(\text{columnas})$$

-Matriz $r \cdot c$



$$f = \begin{bmatrix} f_{0,0} & f_{0,1} & \dots & f_{0,c-1} \\ f_{1,0} & f_{1,1} & \dots & f_{1,c-1} \\ \vdots & \vdots & \ddots & \vdots \\ f_{r-1,0} & f_{r-1,1} & \dots & f_{r-1,c-1} \end{bmatrix}$$

1.3.2.3.-Imágenes como Conjunto de Pixeles

Una imagen I es un conjunto finito no vacío, cuyos elementos son los pixeles (p).

$$I = \{p/p = (\underline{x}, \underline{c}), \underline{x} \in X, \underline{c} = f(\underline{x})\}$$

Dónde: $[\underline{x}, \underline{c}]$ (tupla), \underline{x} (posición), \underline{c} (valor o característica), X (conjunto de posibles posiciones).




Figura 2 .Representación matricial en pixeles de una imagen digital.

Un pixel es un par ordenado $p = (\underline{x}, \underline{c})$ con vector de posición \underline{x} y vector de características \underline{c} . El vector de características describe diferentes características de bajo nivel como nivel de grises, color, textura, bordicidad, etc. Para el caso de imagen en nivel de grises a la información del pixel se le asigna 1 byte, por lo que se permite $256 = 2^8$ niveles de gris (0=negro; 255=blanco) y para color 3 byte (RGB), donde cada pixel consta de 3 valores, pudiéndose obtener 16'777,216 de colores posibles.

Podríamos decir que para una imagen con nivel de grises el valor es escalar o de un solo canal mientras que la imagen a color el valor es vectorial o de tres canales (RGB).



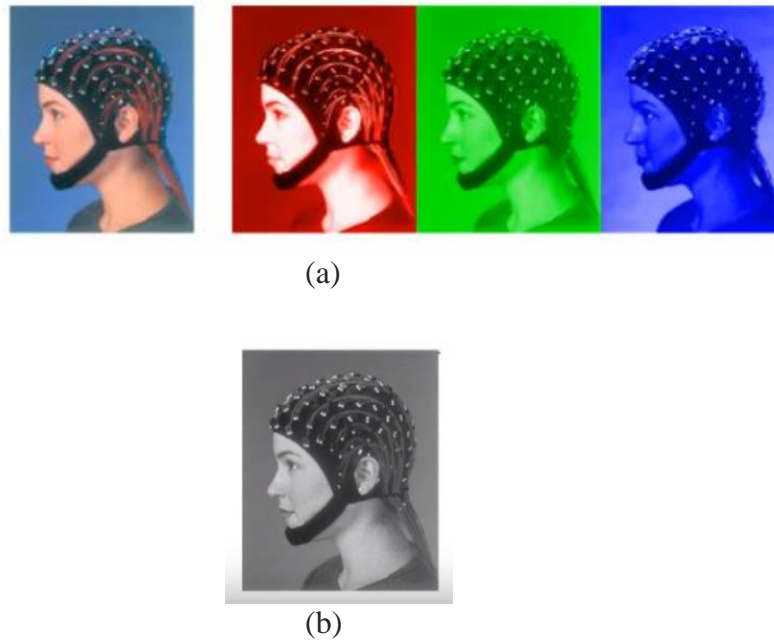


Figura 3. (a) Imagen a color y sus tres componentes RGB, (b) Imagen en escala de grises

De la figura anterior la imagen a color RGB, se unifica de tres matrices a una sola y se aplica la ecuación: $Y = 0.2989R + 0.587G + 0.114B$, obteniéndose valores entre 0 y 255, equivalente a un tono de grises en cada posición de la matriz y en donde el negro=0 y blanco=255. Este proceso se denomina conversión a nivel de grises de la imagen capturada.

En una imagen médica en general los distintos niveles de gris que estudiara el especialista representan algunas propiedades químicas o físicas de la estructura objeto de análisis. En una radiografía de rayos x digitalizada el valor del nivel de grises de cada punto expresa la densidad de área correspondiente. En una tomografía el valor del nivel de grises está relacionado con el coeficiente de atenuación lineal del tejido.



1.3.3.- Relaciones Básicas entre Píxeles

1.3.3.1.-Vecinos de un Pixel

Son los que están en el entorno del pixel de forma horizontal y verticalmente y cuyas coordenadas son:

$$(x+1, y), (x-1, y), (x, y+1), (x, y-1)$$

Este conjunto de píxeles que recibe el nombre de 4-vecinos.

Los píxeles diagonales vecinos tienen coordenadas:

$$(x+1, y+1), (x-1, y-1), (x-1, y+1), (x+1, y-1)$$

Estos puntos, junto con los 4-vecinos, se llaman 8-vecinos.




Figura 4. Píxeles vecinos de un píxel:(a) Cuatro vecinosN4 (p), (b) Ocho vecinosN8 (p).



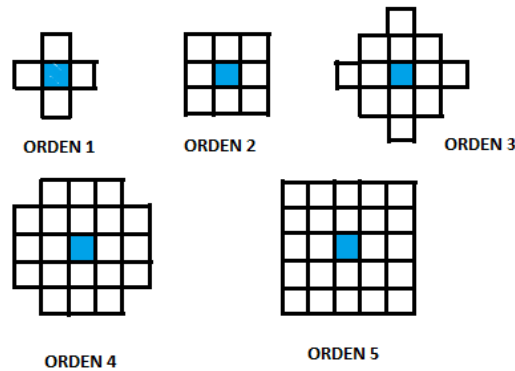


Figura 5. Clasificación del vecindario de un pixel según el orden.

1.3.3.2.-Conectividad

La conectividad entre pixeles establece las fronteras de los objetos con las regiones componentes de una imagen. Para establecer si dos pixeles están conectados debe determinarse si son adyacentes en algún sentido (por ejemplo si son 4-vecinos y sus niveles de gris cumplen algún criterio de similitud, por ejemplo ser iguales).

1.3.4.-Análisis teórico de técnicas y algoritmos utilizados

1.3.4.1.-La operación de convolucion

En el caso de señales unidimensionales, con una sola variable independiente, por ejemplo $(f * g)(x)$, por la operación de convolucion estas señales se traslapan o se multiplican. Por definición el resultado $h(x)$ es:

$$h(x) = \int_{-\infty}^{\infty} f(t)g(x - t)dt$$

Siendo t variable de integración cualquiera, quedando finalmente sobreviviendo x y t desaparece con las operaciones, y siendo $(x - t)$ que se desplaza x o bien a la derecha o a la izquierda t unidades, dependiendo del signo de t .






Figura 6. Operación de convolucion de una señal unidimensional

La señal roja es la función unidimensional a procesar mientras que la señal verde es la matriz o kernel de convolucion que se deslaza, al interactuar produce otra señal convolucionada (señal triangular).

De la figura anterior las señales que convolucionan son rectangulares $f(x)$ y $g(x)$ y la resultante $h(x)=f(x)*g(x)$.

$$h(x) = \left\{ \begin{array}{ll} 0 & t \leq -1 \text{ (desde } -\infty \text{ a } -1) \\ \int_{-0.5}^{0.5+t} dx = t + 1 & -1 \leq t \leq 0 \\ -t + 1 & 0 \leq t \leq 1 \\ 0 & 1 \leq t \end{array} \right\}$$

Al graficar se obtiene la siguiente función triangular:




Figura 7. Señal triangular resultado de la convolucion después de interactuar dos señales rectangulares.



Para el caso de señales bidimensionales indico dos ecuaciones uno para para el caso continuo y el otro para el discreto:

$$f(x, y) \otimes g(x, y) = \int_{t_1=-\infty}^{\infty} \int_{t_2=-\infty}^{\infty} f(t_1, t_2) \cdot g(x - t_1, y - t_2) dt_1 dt_2 \quad \text{ecuación (1)}$$

$$f(x, y) \otimes g(x, y) = \sum_{n_1=-\infty}^{\infty} \sum_{n_2=-\infty}^{\infty} f[n_1, n_2] \cdot g[x - n_1, y - n_2] \quad \text{ecuación (2)}$$

Teóricamente la primera ecuación (1) es una función continua pero para el caso de tratamiento de imágenes el análisis se realiza en el dominio discreto, como en la segunda ecuación (2) (sumatoria de productos).

En el caso de imágenes la convolucion espacial cambia la apariencia de cada pixel en función del valor de luminancia que toman los pixeles de su entorno o de sus vecinos. Por ejemplo en el caso de un filtro espacial, este recorre toda la imagen, pixel por pixel, y se realiza una operación aritmética con un número concreto de pixeles vecinos, reemplazando el valor de este pixel central por el valor ponderado calculado.

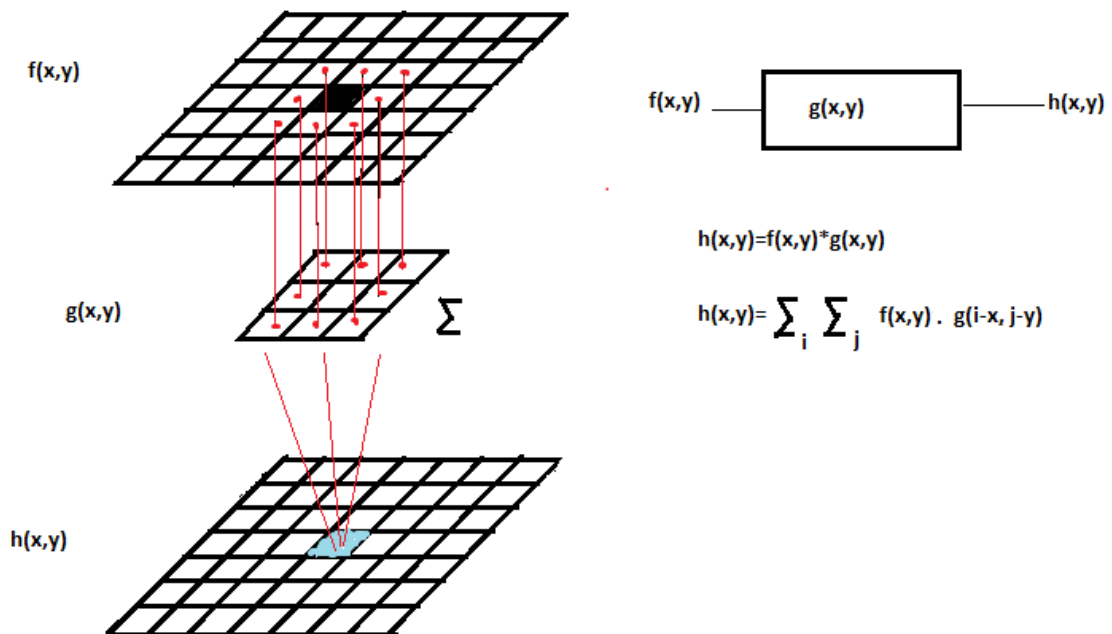


Figura 8.. La matriz de convolucion, en este caso de 3x3 recorre la imagen interactuando con los pixeles de la imagen produciendo una imagen convolucionada.



1.3.4.2.-Filtrado usando Convolucion Espacial

En el filtrado convolucionan dos matrices, la imagen y el filtro(conocido como kernel,ventana o mascara de convolucion).El producto de esta operación matemática es la suma de productosentre los coeficientes del filtro y las intensidades de los pixeles de la imagen dentro de la máscara, desplazándose el kernel por cada pixel de la imagen. Mayormente, la máscara es una matriz cuadrada, de tamaño impar, cuyos valores de los coeficientes determinan el proceso a realizar. El valor del nuevo pixel calculado por el método convolucional, dependerá de los valores de los pixeles de la imagen y de los coeficientes de la mascara.




Figura 9. Pixeles que intervienen en el filtrado espacial por convolucion de la imagen con la máscara o núcleo de convolucion.

En la figura anterior se ilustra cómo se realiza el filtrado espacial,(interviene una máscara de convolucion de 3x3):

$LR5=L1*W1+L2*W2+...L9*W9$, es la respuesta lineal y se recorre todos los pixeles de la imagen.

$W1, W2,...W9$, son los coeficientes de la máscara de convolucion.

$L1, L2,...L9$, son los niveles de gris de la imagen de entrada que se encuentra dentro de la máscara de convolucion.



1.3.4.3.-Filtros de Paso Bajo y Paso Alto

El filtro paso bajo, aumenta el efecto de suavizado, atenúa la alta frecuencia dejando pasar la baja frecuencia. El efecto es una pérdida de nitidez y reducción de ruido (ya que el ruido es alta frecuencia). Difumina los bordes y otros detalles de realce.




Figura 10. Respuesta en frecuencia y tiempo de un filtro paso-bajo



Para disminuir el suavizado se suelen usar otros filtros aumentando el peso del pixel central y entonces el efecto de los pixeles laterales disminuye. Construcciones más suaves, con dependencia de la distancia al pixel central (más lejos coeficiente más pequeño).

No suelen implementarse filtros de 4x4, 6x6,..., ya que se pierde la simetría y no tienen por qué ser cuadrados, sino que pueden tener la forma que uno desee. Es de comentar que se usa un factor de escala como suma de los elementos de la máscara o kernel de convolucion.

Los filtros de realce, paso-alto, tienen como objetivo destacar los detalles finos e intensificar detalles difuminados por error o por el método de adquisición. La clave en los valores de la matriz de convolucion, está en que los coeficientes positivos van en el centro y los coeficientes negativos en la periferia.

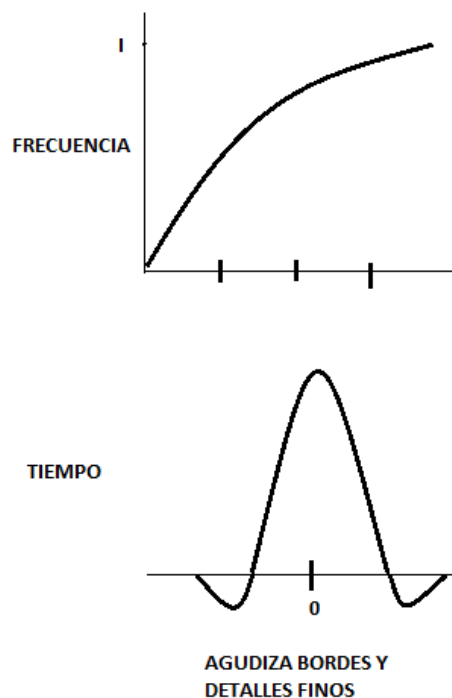


Figura 11. Respuesta en frecuencia y tiempo de un filtro paso-alto



1.3.4.4.-Filtros Diferenciales de primer orden-Gradientes

1.3.4.4.1.-Método Gradiente

El método gradiente hace uso de una derivada para poder identificar los bordes de una imagen. Se ilustra una imagen en una dimensión (función error) que varía de forma continua y suave de -1 a 1. La función brinca de un valor a otro y para identificar este punto se aplica la derivada.




Figura 12. Respuesta de la derivada ante un borde de la imagen

Se puede observar que cuando la pendiente de la recta tangente aumenta la derivada toma un valor creciente y cuando tiende a alcanzar el otro extremo la recta tangente tiende a hacer horizontal y es cuando la derivada toma un valor máximo y la derivada toma un valor decreciente, para luego tomar un valor cero como al comienzo.

1.3.4.4.2.-Filtros Diferenciales

Estos filtros sirven para detectar lados o bordes. El operador local de derivación encuentra el borde si el pixel que pertenece a este borde sufre un cambio brusco entre niveles de grises con sus vecinos. Mientras más brusco sea el cambio, más fácil es detectar el borde. El principal problema que surge en el realce de los detalles de la imagen o la detección de los bordes es que el ruido es colateralmente realzado.



Se define la derivada de una imagen digital en función de las variaciones entre pixeles adyacentes, por lo que la primera y segunda derivada cumplen lo siguiente:

*La derivada de primer orden es cero en pixeles de intensidad constante y valores distintos a cero en escalones o rampas.

*La derivada de segundo orden es cero en pixeles de intensidad constante y en rampas con pendiente constante pero distinta de cero en escalones, en comienzo y fin de rampas.




Figura 13.. Ilustración de la primera y segunda derivada de una función digital unidimensional representándolo en una sección de un perfil de línea de intensidad horizontal.






Figura 14. Perfil de línea mostrando la respuesta de la derivada a los cambios de niveles de gris(a) de una radiografía de tobillo y (b) de una mamografía

La aplicación de la derivada a la función $f(x)$ sería de la forma:

$$\frac{\partial f}{\partial x} = f(x+1)-f(x)$$

$$\frac{\partial^2 f}{\partial x^2} = f(x+1)+f(x-1)-2f(x)$$

En general la derivada de segundo orden es más sensible a las variaciones bruscas en la imagen, detectando en contraparte el ruido.

Una aproximación del gradiente de una imagen sería:

$$\nabla_1 f(x,y) = (\nabla_{x1} f(x,y), \nabla_{y1} f(x,y))$$

Dónde: $\nabla_{x1} f(x,y) = f(x,y) - f(x-1,y)$

$$\nabla_{y1} f(x,y) = f(x,y) - f(x,y-1)$$



Tabla 1. Mascaras utilizadas para aplicar la derivada de 1er orden

0	-1	0
0	0	0
0	1	0

0	0	0
-1	0	1
0	0	0

Se puede observar que estas operaciones diferenciales pueden expresarse en forma de convolucion usando las mascarar respectivas.

1.3.4.5.-Filtros diferenciales de segundo orden-Laplacianos

Para la derivada de segundo orden usamos el laplaciano, considerado como un operador de derivación isotrópico (independiente de la dirección de la discontinuidad en la imagen) definido por:

$$\nabla^2 f = (\partial^2 f / \partial x^2) + (\partial^2 f / \partial y^2)$$

Tabla 2. Mascara utilizada para aplicar la 2da derivada el laplaciano

0	1	0
1	-4	1
0	1	0

La formulación del laplaciano puede implementarse en forma digital de varias maneras. Esta es la más frecuente en la práctica en aplicar la mascara.

Los coeficientes de la máscara utilizada tienen las coordenadas siguientes:

$$\nabla^2 f(x,y)=[f(x+1,y)+f(x-1,y)+f(x,y+1)+f(x,y-1)]-4f(x,y)$$



Tabla 3. Otras mascarar para implementar el laplaciano

1	1	1
1	-8	1
1	1	1

0	-1	0
-1	4	-1
0	-1	0

-1	-1	-1
-1	8	-1
-1	-1	-1

Se observa la descripción de otros modelos de máscaras para implementar el laplaciano digital.

Se puede deducir que al sumar los coeficientes de la máscara el resultado debe ser cero, para el caso de que el pixel en cuestión y su entorno tengan el mismo valor.

Los pixeles del borde darán como respuesta un numero negativo(o positivo) “grande”.

Debido a que el laplaciano es muy sensible al ruido, se suele primero pasar un filtro gaussiano para eliminar ruido, dando lugar al filtro Laplaciano del Gaussiano (LoG).

1.3.4.6.- Histogramas y segmentación por umbralizacion

Se puede definir un histograma como un gráfico que muestra y relaciona la cantidad de pixeles en una imagen por cada valor de intensidad diferente encontrado en esa imagen.

También se puede definir como un conteo de niveles de gris que hay en una imagen o las ocurrencias de niveles de gris de la imagen.

También proporciona el valor de probabilidad de que un determinado rango de niveles de gris aparezca. La forma del histograma depende del tipo de tejido característico de una mamografía.

El histograma de una imagen en un escala de grises de 8 bits hay 256 diferentes intensidades posibles y así el histograma displayara gráficamente 256 valores mostrando la distribución de pixeles alrededor de esos valores de escala de grises.



Se podría definir como un inventario, un conteo del número de píxeles que cumplen con el valor de 0 a 255. Para el caso de Matlab se indexa desde 1, en otros lenguajes de programación como c++ si se indexa desde 0.

El histograma es una herramienta visual, nos da una idea muy aproximada de la distribución de niveles de gris, el contraste que presenta la imagen. Se trata de una curva que relaciona cada uno de los posibles niveles de gris con la frecuencia relativa de aparición del mismo en la imagen.

1.3.4.6.1.-Histograma de una mamografía ideal

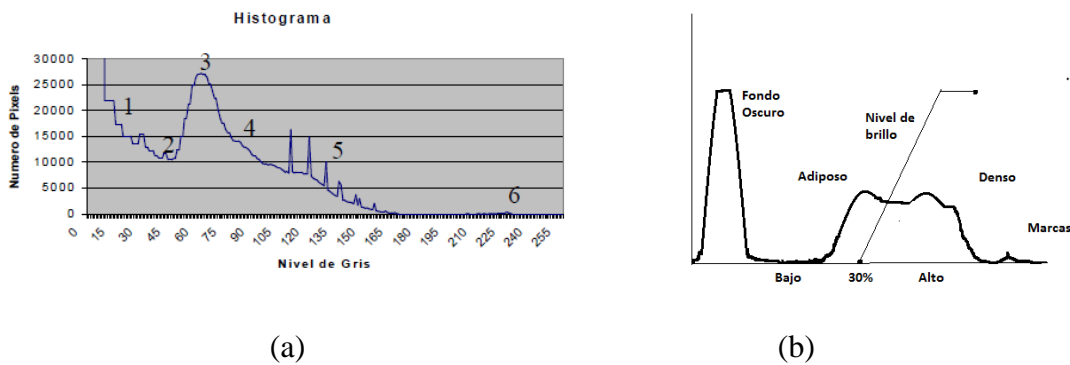


Figura 15. Histogramas de una mamografía ideal.

1.3.4.6.2.-Segmentación por el método de Otsu

En esta investigación utilizo la función “graythresh” de la toolbox de Matlab quien calcula un umbral global utilizando el método de Otsu. A partir de un cálculo estadístico, elige el umbral para minimizar la varianza de dos grupos de píxeles blancos y negros.

1.3.4.7.-Binarización o umbralización simple

La binarización llamada también umbralización simple, forma dos conjuntos uno de todos los píxeles menores al umbral y otro conjunto de píxeles que son iguales o mayores al umbral, formándose una imagen binaria de ceros y unos.

Una definición simple es que se trata de una intensidad o umbral definido T, que lleva a las salidas de $f(x, y)$ a pertenecer a grupos distintos basados en su relación a T.



Con esta forma de umbralizar o binarizar quedan finalmente aislados los objetos en estudio, las microcalcificaciones. Utilizo la función “im2bw de la toolbox de Matlab, cuyos parámetros de entrada son la imagen y el umbral calculado con el método de otsu.

1.3.4.8.-Ecuación del Histograma

Gonzales Marcos et al., 2006, en su publicación “Técnicas y Algoritmos básicos de visión artificial”, p. 52, dicen que cuando el histograma de una imagen reporta intensidades concentradas esta imagen es de pobre contraste debido a que su luminosidad tiene un angosto rango de niveles de grises desaprovechándose gran parte de ella. Entonces la ecualización reparte los pixeles agrupados por todo el rango, distribuyéndose y por consiguiente aumentándose el contraste, distinguiéndose mejor los objetos pero a cambio de aumentar el ruido.

Manzano L. (2015), nos dice que la ecualización adaptativa del histograma con contraste limitado, y que utilizo en esta tesis para realzar el contraste del objeto microcalcificación, al distribuir en todo el rango los pixeles con valores cercanos, mejora la visibilidad y ayuda en la extracción posterior de los descriptores al situar las microcalcificaciones en un rango de valores similar.

Dicho con otras palabras la ecualización del histograma transforma los niveles de gris, de tal manera que la distribución sea uniforme, obteniéndose un nuevo histograma aproximadamente llano y lineal. Por todo anterior, esta técnica de ecualización del histograma aporta ayuda para que posteriores procesos tengan mejor acierto.

1.3.4.9.-Corrección Gamma

Fernando L, Zulma C.(2007), dice que en general la corrección gamma refuerza la calidad o aspecto de una imagen observándose hasta pequeños detalles, aumentado el contraste en áreas muy claras o muy oscuras modificando los valores medios-bajos sin tocar los pixeles blancos(255) ni negros(0).

Matemáticamente por ley de potencias se define:

$$V_{out} = A (V_{in})^{\gamma}$$

Dónde: V_{out} (salida), A (constante), V_{in} (entrada), γ (corrección gamma).

Cuando:

A=1, las entradas y salidas caen típicamente en el rango 0-1,



$\gamma < 1$ (compresión de la imagen),

A la inversa $\gamma > 1$ (expansión de la imagen).

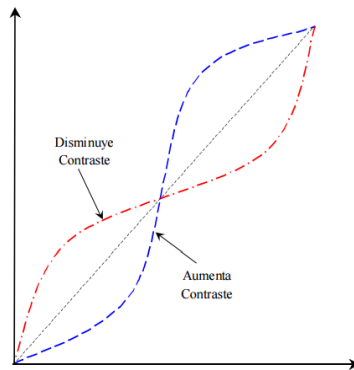


Figura 16. Curvas de transferencia para la corrección gamma

Gonzales M, Ana et al. (2006), comenta que para aumentar o disminuir el contraste de una imagen aparece el factor de corrección gamma, usado en múltiples programas de diseño y tratamiento de imágenes. Y como se observa en la figura anterior si este factor es 1 nos encontramos en la línea recta diagonal, si es menor a 1 la curva pasa por encima de esta línea diagonal, y si es mayor la curva pasa por debajo.

1.3.4.10.-La Transformada TOP HAT

Platero, Carlos (2008) en su libro “Apuntes de Visión Artificial”, indica que el objetivo de las transformaciones morfológicas es la extracción de estructuras geométricas en los conjuntos en los que se opera, mediante la utilización de otro conjunto conocido como elemento estructurante, cuyo tamaño y forma se elige de acuerdo a la morfología del conjunto sobre el que se va a interaccionar y de acuerdo a la extracción de formas del elemento estructurante (SE).

Las aplicaciones básicas de la morfología matemática son operaciones de erosión, dilatación, apertura y cierre.

1.3.4.10.1.-Erosión binaria

Es una operación morfológica donde el elemento estructurante B está completamente incluido dentro del conjunto A_i (imagen de entrada).



$$\epsilon(A_i) = A_i \ominus B = \{Z / B_z \subseteq A_i\}$$

Donde: Z conjunto de pixeles de la erosión, ubicados en cualquier lugar de la imagen y que cumplen la condición de inclusión. Entonces los pixeles blancos que no cumplen se pintan de negro.

Los objetos son eliminados cuando son menores que el elemento estructurante.

En conclusión con la erosión los objetos que resultan de la transformación habrán sido degradados y si se vuelve aplicar iterativamente los objetos desaparecerán, por lo que la erosión es una transformación antiextensiva.

$$\epsilon(A_i) \subseteq A_i$$

1.3.4.10.2.-Dilatación Binaria

Es la transformación dual a la erosión. El resultado de la dilatación es el conjunto de elementos(x) tal que al menos algún elemento del conjunto estructurante B está contenido en el conjunto A_i , cuando B se desplaza sobre el conjunto A_i :

$$D(A_i) = A_i \oplus B = \{x / A_i \cap B_x \neq \emptyset\}$$

El resultado de esta operación es el crecimiento de la imagen.

La dilatación es una transformación extensiva:

$$A_i \subseteq D(A_i)$$

Las aplicaciones de las operaciones de erosión seguida con una dilatación no son conmutativas. Los resultados dan paso a las aperturas y cierres morfológicos.

Para las aperturas, siendo A_i , la imagen de entrada, calculamos así la apertura realizada con el elemento estructurante B. Primero se realiza la erosión de A_i mediante B, seguida por la dilatación de la imagen intermedia resultante por B:

$$A_i \odot B = (A_i \ominus B) \oplus B$$



La imagen resultante ha eliminado los objetos de radio menor al elegido pero conserva todavía el nivel medio de gris fondo con estructuras mayor a dicho radio.

Aplicamos la transformada Tophat restando a la imagen original la apertura de la misma obteniendo la imagen T_i :

$$T_i = T_{\text{hat}}(A_i) = A_i - (A_i \odot B).$$

1.3.4.11.-Redes neuronales

Una red neuronal se puede usar por ejemplo si se quiere predecir si una pareja de esposos se van a divorciar de acuerdo a datos acerca de sus edades, costumbres, número de hijos que tienen, área de la casa donde viven, etc.

Todos estos datos se ingresan a la red neuronal y a lo mejor inicialmente no coincide con lo que realmente sucedería según experiencias por lo que se tiene que someter a la red a entrenarla hasta obtener un resultado deseado haciendo que el error disminuya después de varios entrenamientos.

1.3.4.11.1.-Red Neuronal Biológica




Figura 17. Neurona Biológica

Las redes neuronales artificiales se basan en las neuronas biológicas. Y a propósito se ha llegado a determinar que las neuronas de un cangrejo tienen un diámetro de 30 μm y procesan la información a $\sim 18 \text{ km/h}$, en las de un calamar su diámetro es de 500 μm y la



información corre a ~72 km/h en cambio en un ser humano las neuronas tiene un diámetro de ~20 um y procesan la información a ~432km/h.




Figura 18. El paso de la información sucede gracias a la sinapsis, que son conexiones entre neuronas, sucediendo así el paso de la información de una neurona a otra, y entonces la intensidad o la fuerza de estas conexiones se le llama peso sináptico.




Figura 19. Después de procesos de multiplicación, suma y activación la señal llega a otras neuronas.

1.3.4.11.2.-Modelo Matemático de una Neurona




Figura 20. Modelo matemático de una neurona



$$a_i = f \left(\sum (w_{ij} \cdot p_i + b_i) \right)$$

Dónde: p_i (entradas o patrones), w_{ij} (pesos sinápticos), b_i (polarización) n_i (entrada neta), a_i (salida-axon) y f (función de activación).

1.3.4.11.3.-Funciones de Activación

La función de activación es la encargada de definir la salida de la neurona. Las funciones de activación más comunes son:

1.-Funcion Identidad

$$f(x) = x$$

2.-Funcion Escalón

$$f(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases}$$

ó

$$f(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ -1 & \text{si } x < 0 \end{cases}$$

3.-Funcion Lineal Saturada

$$f(x) = \begin{cases} -1 & \text{si } x \leq -1 \\ X & \text{si } -1 < x < 1 \\ 1 & \text{si } x \geq 1 \end{cases}$$

4.-Funcion Sigmoidal

$$f(x) = 1/(1 + e^{-ax})$$

5.-Funcion Tangente Hiperbólica

$$f(x) = (1 - e^{-ax})/(1 + e^{-ax})$$

6.-Funcion Gaussiana

$$f(x) = Ae^{-B(x^2)}$$






Figura 21. Funciones de activación aplicadas en las RNA.(a)Identidad.(b)Escalon.(c)Lineal Saturada.(d)Sigmoidal.(e) Tangente Hiperbólica.(f)Gaussiana.

Con el entrenamiento o aprendizaje una red neuronal aprende a realizar una tarea. De forma matemática, consiste en la modificación de los pesos para lograr la meta propuesta en el entrenamiento.



1.3.4.11.4.-Algoritmo de Backpropagation

Es un lazo de retropropagación o propagación hacia atrás de errores, para minimizar el error de salida de la red utilizando el algoritmo del descenso del gradiente.

Se utiliza como un método para calcular las derivadas parciales de cada uno de los parámetros de nuestra red con respecto al coste, para luego optimizar la red neuronal haciendo uso del algoritmo del descenso del gradiente. Para minimizar el coste, el error de la red, entrenar a la red, se necesita el vector gradiente y es un vector que contiene las derivadas parciales de estos parámetros con respecto al coste, siendo que estas derivadas lo da el algoritmo de Backpropagation.

1.3.5. -Sistema de Base de Datos e Informes de Imágenes del Seno (BI-RADS)

El Colegio Estadounidense de Radiología (American College of Radiology, (ACR)) ha establecido un método uniforme para que los radiólogos describan los resultados de las mamografías. El sistema, llamado BI-RADS (Breast Imaging Reporting and Database System), consiste en siete categorías o grados generalizados. Cada categoría del BI-RADS tiene un plan de seguimiento asociado para ayudar a los radiólogos y a otros médicos a manejar adecuadamente el cuidado de las pacientes. El objetivo de este sistema de categorización de lesiones mamarias es estandarizar el informe y el lenguaje mamográfico para facilitar la comunicación entre los diferentes especialistas implicados en el manejo de la patología mamaria.



1.3.5.1.- Clasificación de las etapas de la lesión cancerígena en mamografías

Tabla 4.-Clasificación segun categorias de la lesión cancerígena en las mamas.

CATEGORIA	EVALUACION	SEGUIMIENTO
0	Requiere una evaluación adicional y/o mastografías anteriores para su comparación.	Requiere más estudios con ultrasonido o resonancia magnética.
1	Negativo	Examen normal. Continuar las mamografías regulares de detección (para mujeres mayores de 40 años de edad)
2	Resultado benigno (no canceroso)	Continuar las mamografías regulares de detección (para mujeres de 40 años de edad)
3	Probablemente benigno	Hacerse una mamografía de seguimiento a los seis meses
4	Anomalía sospechosa con mastografía y ultrasonido	Puede requerir biopsia 4A: Baja sospecha de malignidad 4B: Moderada sospecha de malignidad 4C: Alta sospecha de malignidad.
5	Muy probable que sea maligno (cáncer)	Requiere biopsia
6	Malignidad reconocida, comprobada por biopsia (cáncer)	Biopsia confirma la presencia de cáncer antes de iniciar tratamiento

Las patologías de la mama pueden ser de dos tipos: las opacidades infraclínicas, que incluyen las distorsiones de la estructura mamaria y las masas tumorales, y la otra parte son las microcalcificaciones.



La clasificación de estas microcalcificaciones se divide en los cinco tipos que se muestran a continuación:

Tabla 5.-Clasificación de las microcalcificaciones según su morfología

Tipo	Forma
I	Microcalcificaciones anulares, redondeadas, de centro claro, (0% Malignidad).
II	Microcalcificaciones puntiformes regulares, redondeadas, (10% Malignidad). Las de tipo vasculares, cutáneas, en lechada de cal, lineales gruesas, en pop corn, distroficas, redondas dispersas o aisladas, en anillo y de sutura.
III	Microcalcificaciones "en polvo", muy finas, sin poder precisar su forma ni su número (19% Malignidad). Las de tipo redonda agrupada.
IV	Microcalcificaciones puntiformes irregulares, son poliédricas, en grano de sal (29% Malignidad). Las de tipo toscas groseras o heterogéneas, amorfas, finas pleomorficas.
V	Microcalcificaciones vermiculares, son alargadas, como un árbol sin hojas (72% Malignidad). Las de tipo lineales, lineales ramificadas y de distribución segmentaria.

Con esta clasificación de acuerdo a este patrón de morfología se logra describir las microcalcificaciones presentes en las imágenes mamográficas.






Figura 22. Clasificación de las microcalcificaciones según un patrón de distribución

Con estos tipos y formas finalmente en la etapa de reconocimiento e interpretación se quiere clasificar y realizar un reconocimiento de patrones geométricos, entrenando la red con estos patrones para que aprenda y que luego al correr la imagen a analizar, la red debe reconocer el tipo de malignidad o benignidad que está presente en la imagen mamográfica.

1.3.6.- Extracción de características del objeto microcalcificación

Para poder clasificar regiones u objetos en imágenes, es necesario extraer un conjunto de características del objeto o región, que permitan diferenciarlo de otras clases de objetos. A continuación se describen las características utilizadas en la etapa de reducción de falsos positivos propuesta en esta tesis, dando una breve descripción de cada una de ellas y la forma en que se calculan.



1.3.6.1.- Características o descriptores de forma y localización

Extraídas y diferenciadas los objetos de la imagen binaria, las características geométricas más asequibles que se pueden identificar de ellas son las siguientes entre otras:

Numero de microcalcificaciones

Se cuenta el número de áreas de objetos que han sido segmentados.

Área

Un simple recuento del número de píxeles que forman el objeto da cuenta del área de la forma:

$$A(R) = \sum_{i=1}^n 1 = n * C = n$$

Siendo R, una región diferenciada de la imagen y n el número total de píxeles de la región R.

Excentricidad

Es el radio de la distancia entre el foco de la elipse más pequeña que contiene a la región y la longitud del eje mayor de ésta, este valor se encuentra entre 0 y 1.

Longitud del eje mayor

Indica la longitud en píxeles del eje mayor de una elipse de tamaño más pequeño en la que cabe la región.

Longitud del eje menor

Indica la longitud en píxeles del eje menor de la elipse de menor tamaño donde cabe la región.

Diámetro

En el caso de un objeto circular el diámetro mayor es igual al diámetro menor, caso contrario hay un diámetro mayor y otro menor.

Solidez

Define la cantidad de píxeles que se encuentran dentro de una región y el área convexa de ésta.

Perímetro

El perímetro de un objeto se puede definir como la cantidad de píxeles de este que están en contacto con el fondo en su contorno externo (ya que cabe la posibilidad que este objeto albergue huecos dentro de sí). Este contorno externo con una vecindad de píxeles



de V_8 , se comportaría como la línea de pixeles interconectados de fondo que delimitan el objeto en su zona externa. De esta forma contando la cantidad de lados de los pixeles del contorno externo que están en contacto con la región estudiada se puede definir el perímetro:

$$P(R) = \sum_{i=0}^n li$$

Con R , la región (objeto) diferenciada de la imagen, n el número de pixeles del contorno externo que contiene la región R y li la cantidad de lados del pixel del contorno externo i que limitan con el objeto R .

Algunos autores realizan una corrección del perímetro, $P_{corr}(R)$ exponiendo una sobrestimación del mismo al ser calculado por métodos tradicionales mediante la siguiente ecuación:

$$P_{corr}(R)=0.95.P(R).$$




Figura 23. El perímetro de un objeto se puede definir como la cantidad de pixeles del contorno

Centroide

El centroide es un punto que define el centro geométrico de un objeto. Su localización puede determinarse a partir de fórmulas semejantes a las utilizadas para determinar el centro de gravedad o el centro de masa del cuerpo.

Circularidad

Se compara la redondez del objeto microcalcificación con una forma ideal, llamándola circularidad:

$$\text{Circularidad} = K \cdot A(R)/P^2(R)$$



Siendo K una constante que condiciona la circularidad $(R)=1$ para un círculo perfecto.

Para el caso circular se obtiene:

$$\text{Circularidad}(R) = 1 = K \cdot (\pi \cdot r^2) / (2 \cdot \pi \cdot r)^2$$

$$K = 4 \cdot \pi$$

Finalmente la ecuación quedaría:

$$\text{Circularidad} = 4 \cdot \pi \cdot A(R) / P^2(R)$$

Esta ecuación dará como resultado entre $[0,1]$ según la semejanza de la forma a la relación área-perímetro ideal de un círculo perfecto. Regiones con exceso de perímetro, según la relación propia de un círculo con área equivalente harán que la circularidad (R) se aproxime a valores cercanos a cero.




Figura 24. Circularidad o relación área-perímetro para diferentes formas.

Elongacion

El concepto de elongacion se refiere al estiramiento o dilatacion que puede tener el objeto microcalcificacion.

Forma

Las formas simples se pueden describir mediante objetos básicos de geometría tales como un conjunto de dos o más puntos, líneas rectas, curvas, planos, figuras planas (por ejemplo, un cuadrado o un círculo), figuras sólidas (por ejemplo, el cubo o la esfera)

1.3.6.2.-Características basadas en el valor de intensidad del píxel o descriptores de intensidad

Nivel medio de intensidad

Escalar que indica la media de todos los valores de intensidad de los píxeles dentro de la región.



Desviación Estándar

Proporciona el nivel de contraste de la región.

Oblicuidad

La oblicuidad es una medida de que tan asimétrica es una distribución alrededor de su media.

Kurtosis

La kurtosis (o apuntamiento) es una medida de forma que mide cuán escarpada o achatada está una curva o distribución. Este coeficiente indica la cantidad de datos que hay cercanos a la media, de manera que a mayor grado de kurtosis, más escarpada (o apuntada) será la forma de la curva.

Nivel mínimo de intensidad

Escalar que indica el valor del píxel con la intensidad más baja de una región.

Nivel máximo de intensidad

Escalar que indica el valor del píxel con la intensidad más alta de una región.

1.4. Formulación del Problema

¿Cómo lograr la identificación automática de microcalcificaciones en imágenes digitales de mamografía, usando algoritmos y técnicas para el tratamiento y análisis de imágenes así como un clasificador a base de una red neuronal, con la principal finalidad de contribuir en el descarte y detección del cáncer de seno?

1.5. Justificación e Importancia de la Investigación**1.5.1. Científica**

Este trabajo reforzará el área de investigación e innovación científica sobre el análisis automático de imágenes mamográficas para el reconocimiento e identificación de patologías neoplásicas mamarias y por consiguiente ayudará con su aplicación a la detección y diagnóstico clínico.

1.5.2. Institucional

Este trabajo de investigación intenta contribuir con la detección temprana del cáncer de mamas, desarrollando las mejores técnicas y algoritmos que ayuden al especialista radiólogo, a la detección eficaz y confiable de microcalcificaciones, beneficiando así hospitales locales y a sus médicos, ya que brindará un aporte en los diagnósticos logrando detectar, tratar y prevenir a tiempo esta enfermedad neoplásica.



1.6. Hipótesis

La utilización de técnicas y algoritmos así como técnicas de reconocimiento de patrones permitirá la identificación y reconocimiento de microcalcificaciones en regiones de interés extraídas de imágenes digitales de mamografía.

1.7. Objetivos de la Investigación

1.7.1. Objetivo general

Utilizar técnicas y algoritmos así como un clasificador neuronal para la identificación automática de microcalcificaciones en imágenes digitales de mamografía.

1.7.2. Objetivos específicos

- a) Definir requerimientos funcionales para el desarrollo de la aplicación.
- b) Seleccionar algoritmos de procesamiento de imágenes digitales.
- c) Implementar algoritmos.
- d) Seleccionar un clasificador automático.
- e) Realizar pruebas del sistema (validación).

II. MATERIAL Y METODO

2.1. Tipo y Diseño de Investigación

2.1.1 Tipo de investigación

El tipo de investigación es explicativa y cuantitativa, porque se analizan las técnicas y algoritmos para luego evaluar y seleccionar al más eficaz en la detección e identificación de objetos patológicos en imágenes digitales de mamografía.

2.1.2 Diseño de la investigación

El diseño es experimental del sub tipo cuasi-experimental porque demostrara la hipótesis a través del análisis y experimentación de técnicas y algoritmos, buscando la detección e identificación de microcalcificaciones presentes en imágenes digitales de mamografía.

2.2. Población y Muestra

La población está conformada por los casos clínicos de reportes de pacientes con biopsia en la unidad de diagnóstico por imágenes del Hospital Nacional Almanzor Aguinaga Asenjo y periferia de Chiclayo (Red asistencial Lambayeque-Essalud).

La muestra son casos clínicos comprendidos en el periodo 2017-18-19.

Se seleccionó imágenes para entrenamiento de la red neuronal (9 benignas y 9 sospechosas).

Las imágenes para el test (para probar la red neuronal experimentada) fueron 6 benignas y 6 sospechosas.

2.3. Variables, Operacionalización

2.3.1. Variable Independiente

Utilización de técnicas y algoritmos para la identificación y reconocimiento de microcalcificaciones en regiones de interés extraídas de imágenes digitales de mamografía.



Tabla 6.-Operacionalización de la variable independiente

Dimensión	Indicador	Categoría	Técnicas e Instrumentos de recolección de datos
Decibelios, dB)	Reducción de ruido aleatorio	Técnicas y algoritmos de filtrado convolucional	Error Cuadrático Medio (ESM), mide la diferencia entre imágenes. Relación Señal Ruido (PSNR).
Relación entre contrastes de la imagen procesada y la original (adimensional)	Realce o mejora de contraste en las imágenes	Técnicas y algoritmos de realce de contraste	Índice de mejoramiento de contraste (CII, Contrast Index Improvement).
Áreas o regiones bien diferenciadas.	-Identificación y aislamiento de la clase microcalcificación	Técnicas y algoritmos de segmentación	Observación
Descriptores Morfológicos y de intensidad	Descripción del objeto microcalcificación	Vectores o patrones de características	Cálculo computacional

Con esta tabla se logró dimensionar la variable independiente.

2.3.2.Variable Dependiente

Identificación y reconocimiento automático de microcalcificaciones, quienes son objetos o elementos anormales en regiones de interés extraídas de imágenes digitales de mamografía.



Tabla 7.-Operacionalización de la variable dependiente

Dimensiones	Indicadores	Categoría	Técnicas e Instrumentos de recolección de datos
Porcentaje (%)	Sensibilidad, especificidad, precisión, exactitud y tasa de error.	Clasificador a base de una red neuronal	-Tablas y gráficos Curva ROC y área bajo la curva AUC -Validación

Con esta tabla se logró dimensionar la variable dependiente.

2.4. Técnicas e instrumentos de recolección de datos, validez y confiabilidad

En las primeras etapas del método utilizo la observación y análisis de imágenes para luego con ayuda de métricas elegir las mejores técnicas y algoritmos, para finalmente llegar al objetivo final de detectar, identificar y clasificar las microcalcificaciones, quienes son catalogados como signos tempranos de cáncer de mama.

Técnicas de recolección de datos:

Se recolectan datos luego de realizar cálculos computacionales en Matlab utilizando métricas, cálculos estadísticos orientados a imágenes, y experimentación de la red neuronal en Neuroph studio.

Instrumentos de recolección de datos:

Materiales

- Imágenes mamográficas de hospitales de la red Asistencial Lambayeque-Essalud, extraídos de los digitalizadores CR y de tomosíntesis
- Entorno de aplicación matemática y científica: Matlab. R2013b (64 bit).
- Marco orientado a objetos de redes neuronales escrito en java: Neuroph studio



-Sistema computacional

Intel (R) Core (TM) i5-3210M CPU (2.5 GHz).Sistema operative de 64 bits.

A continuación se describen herramientas estadísticas y métricas para recolección de datos en búsqueda del logro de los objetivos de filtrado, realce de contraste, segmentación y clasificación.

2.4.1. La media aritmética y la desviación estándar

Se utiliza la media y la desviación estándar para realizar un análisis contextual del entorno y evitar que por la falta intensidad de grises o el ruido esta información sea confundida por una microcalcificación, para luego con estos datos y otros descriptores construir los patrones que entraran al clasificador basado en una RNA para la detección de microcalcificaciones.

En imágenes la media o promedio lo obtenemos así:

$$I_u(x, y) = \left(\frac{1}{m \times n}\right) \sum_{x=1}^m \sum_{y=1}^n f(x, y) \quad (\text{brillo de la imagen})$$

y la desviación estándar (que tan dispersos están los datos) se obtiene según la fórmula:

$$I_o(x, y) = \text{sqrt} \left[\left(\frac{1}{m \times n}\right) \sum_{x=1}^m \sum_{y=1}^n (f(x, y) - I_u(x, y))^2 \right] \quad (\text{contraste de la imagen})$$

2.4.2. Métricas de uso común para comparar la calidad entre dos imágenes luego de un proceso de restauración: MSE (Error Cuadrático Medio) y PSNR (Peak Signal to noise Ratio)

El error medio cuadrático mide la diferencia entre la imagen original y la procesada. Mientras mayor sea mejor calidad del contraste se tiene.

El PSNR mide cuan efectiva es la reducción del ruido en la imagen en decibelios (db).



$$\text{PSNR}=10*\log_{10} ((\text{MaxI}^2)/\text{MSE}) \text{ dB}$$

dónde: $\text{MaxI}=255$ (máximo valor posible del pixel de la imagen) y MSE (Error Cuadrático Medio).

2.4.3. Metrica para la evaluacion del realce de contraste(CII)

Se define un primer plano u objetos de interés (foreground) y un fondo (background).

En este estudio se toma como primer plano el recorte (f) y como fondo el resto de la imagen (b).

$$\text{CII} = C_p / C_o$$

Donde C_p y C_o corresponden a los contrastes de la imagen ROI mejorada o procesada (C_p) y de la imagen original(C_o), respectivamente.

$\text{CII} > 0$, cuanto mayor sea su valor mayor será la calidad del contraste.

2.4.4. Evaluación del desempeño del clasificador (sensibilidad y especificidad)

Se grafica la relación sensibilidad y especificidad en la curva ROC(caracterisitca operativa del receptor) para determinar la capacidad discriminate del clasificador.

Tambien los siguientes términos utilizo para indicar el desempeño del clasificador:

FN (Falsos Negativos)

Son casos en que el clasificador predice que son microcalcificaciones benignas (negativos) pero se comprueba en la realidad que son sospechosas, por lo que la predicción ha sido incorrecta (falso).

FP (Falsos Positivos)

Son casos en que en el reconocimiento de patrones las microcalcificaciones fueron clasificados como sospechosas (positivos) y se prueba que son benignas, por lo que el pronóstico ha sido incorrecto(falso).

TN(Verdadero Negativo)



Son los casos en que los datos son cero(0=falso) y el pronostico también es cero(0=falso). Datos nos indican que no tiene cáncer y el modelo también predice que no tiene cáncer.

TP(Verdadero Positivo)

Son los casos en que los datos son uno(1=verdadero) y el pronostico también es uno(1=verdadero). Datos nos indican que tiene cáncer y el modelo también predice que tiene cáncer.

		PREDICCIÓN	
		POSITIVOS	NEGATIVOS
OBSERVACION	POSITIVOS	VERDADERO POSITIVO(TP)	FALSO NEGATIVO (FN)
	NEGATIVOS	FALSO POSITIVO (FP)	VERDADERO NEGATIVO(TN)

Figura 25. Matriz de confusión en el desempeño del sistema

Las métricas usadas para reportar el desempeño son:

(1) Matriz de confusión= $\begin{pmatrix} TP & FN \\ FP & TN \end{pmatrix}$

(2) Exactitud = $\frac{TP+TN}{(TN+FP+FN+TP)=total}$ (porcentaje de la data clasificada correctamente)

(3) Tasa de error = $\frac{FP+FN}{(TN+FP+FN+TP)=total}$ (porcentaje de la data clasificada incorrectamente)

(4) Sensibilidad = $\frac{TP}{(FN+TP)=total\ de\ positivos}$ (tasa de verdaderos positivos, cuando la clase es positiva, que porcentaje logra clasificar correctamente)



(5) Especificidad = $\frac{TN}{(FP+TN)=total\ de\ negativos}$ (tasa de verdaderos negativos, cuando la clase es negativa, que porcentaje logra clasificar correctamente)

(6) Precisión = $\frac{TP}{(TP+FP)=total\ clasificados\ positivos}$ (cuando predice positivos, que porcentaje clasifica correctamente)

2.5.. Procedimientos de analisis de datos

La información que se recopila en las primeras etapas se obtiene de la observación, descripción y análisis de las imágenes procesadas, gracias a los datos obtenidos de los cálculos estadístico, de los gráficos y tablas comparativas de elaboración propia. Luego finalmente la decisión si la anomalía es benigna o sospechosa corre a cargo de una red neuronal.

El software utilizado es Matlab, con un lenguaje de programación propio (lenguaje M), donde se implementan los algoritmos de procesamiento digital para luego observar resultados después de revisar gráficos, información en el workspace de Matlab, imágenes y tablas de comparación de resultados. Con ayuda de la herramienta matemática de Matlab y con el framework Neuroph Studio se ensaya la red neuronal como clasificador.

Los gráficos, los histogramas muestran la efectividad de las técnicas de filtrado y de realce de contraste de las imágenes en estudio y con ello elegir el más idóneo. La información recolectada con estas herramientas informáticas será analizada, interpretada y validada permitiendo llegar a los objetivos.

2.6. Criterios éticos

Criterios

Características éticas del criterio

Medio ambiente

Se tomarán en cuenta criterios para el cuidado del medio ambiente, aunque el trabajo de investigación no implica alguna contaminación ambiental.



Confidencialidad y privacidad

La información recogida es confidencial. Nadie, excepto el investigador y sus asociados, pueden tener acceso a la información. Al utilizar los datos, el investigador debe asegurarse que nadie identifique, o relacione la información con el participante.

Objetividad

En este trabajo de investigación trato de ser objetivo, porque en base a lo que razono, observo y analizo, deduzco una conclusión basándome en criterios técnicos e imparciales.

Originalidad

En esta investigación trato de ser original, no copiando ni imitando a los demás.

Se citarán las fuentes bibliográficas de la

información mostrada, a fin de demostrar la inexistencia de plagio intelectual.

Veracidad

Principio sencillo, en esencia el más vulnerado en la investigación científica. La regulación aclara que: —No incluye el error honesto o las diferencias honestas en la interpretación o juicio de los datos. La palabra honestidad, sinónimo de verdad, nos invita a presentar a las autoridades la información sin ser manipulada.

La información que se muestra en este trabajo es verdadera y confiable.



Derechos laborales

La propuesta de solución propiciará el respeto a los derechos laborales en la entidad de estudio.

2.7. Criterios de rigor científico

En este trabajo se expresa el rigor científico de la investigación, a partir de la valoración de criterios tales como: la credibilidad, la transferibilidad, dependencia, confirmabilidad y la coherencia de la investigación en conjunto.

Criterios

Características científicas del criterio

Confiabilidad

Aseguro que los instrumentos de recolección de datos sean confiables o produzcan resultados consistentes y coherentes aun de manera repetitiva.

Se realizarán cálculos estadísticos para la determinación del nivel de consistencia interna de los instrumentos de recolección de datos.

Validación

Se validarán los instrumentos de recolección de datos y la propuesta de solución a través de Juicio de Expertos.

Contrastación

Se contrastará la hipótesis a través de métodos estadísticos debido al diseño pre experimental.



III. RESULTADOS

3.1.-Resultados y análisis en tablas y figuras

Los algoritmos de filtrado que se implementaron fueron los siguientes: Filtro box 5x5 (Fbox 5x5), FiltroGaussiano (Fgauss), Filtro de la Mediana(Fmediana), Filtro Gradiente ó de 1er orden (Fgrad) y filtro laplaciano ó de 2do orden (Flap).

La eficiencia de las diferentes técnicas de reducción de ruido sobre una imagen, es comparada con base en el valor de PSNR o relación pico señal a ruido, que indica un buen desempeño de la técnica entre más alta sea su magnitud.

Tabla 8.-Valores de la relación señal-ruido con diferentes técnicas de filtrado

Imagen/Filtro	Fbox 5x5	Fgauss	Fmediana	Fgrad	Flap
CC(D)	30.19 dB	32.85 dB	45.7 dB	9.62 dB	9.62 dB
CC(I)	32.64 dB	35.56 dB	45.8 dB	9.50 dB	9.49 dB
MLO(D)	30.43 dB	33.34 dB	46.06 dB	6.94 dB	6.93 dB
MLO(I)	31.11 dB	34.06 dB	45.68 dB	6.79 dB	6.79 dB

Se observa filtros Fbox 5x5, F ganss, Fmediana, Fgrad y Fap relacionados a CC(D), CC(I), MLO (D) Y MLO (I).

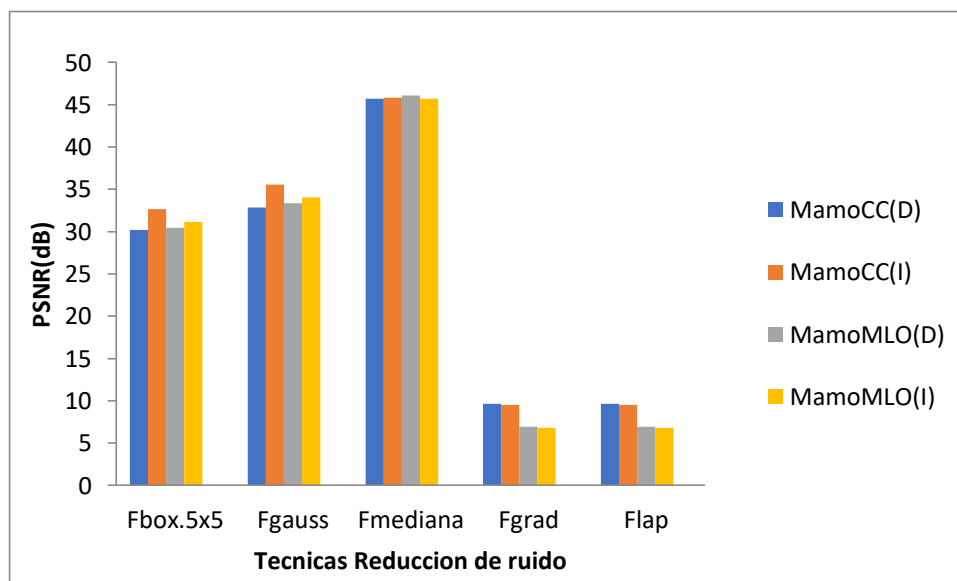


Figura 26. Grafica de comparación de las diferentes técnicas de filtrado experimentadas.



Se utilizaron estas técnicas de filtrado para reducir el ruido en las imágenes, para obtener áreas más homogéneas libre de información que no se considere relevante, para el logro de objetivos en posteriores etapas del método.

En el caso del filtro gaussiano se implementa con mascara que intentan imitar una función gaussiana. Este filtro tiene el inconveniente de empañar la imagen ocasionando pérdidas de los detalles más finos pero el ruido si es removido.

En el filtro box o promediador se reemplaza cada pixel por el promedio del nivel de gris de los pixeles vecinos. Este filtro tiene el efecto indeseado de suavizar también los bordes, que son características generalmente deseadas.

En el filtro de la mediana se reduce el ruido y en especial reduce el desenfoque de los bordes al sustituir el valor de gris del pixel central por la mediana de los valores de los vecinos más cercanos, de ahí que se trate de un filtro no lineal que conserva detalles de la imagen.

Al experimentar con los filtros gradiente y laplaciano no se obtiene rechazo al ruido pero se concluye que sirven para detectar bordes.

Luego de observar y comparar resultados, el filtro de la mediana es el que tiene la mejor relación señal-ruido (46.06 dB).

Para las técnicas de realce de contraste se implementaron los algoritmos siguientes: Ecuación del histograma (EQH), corrección gamma con exponente menor a 1 ($CG < 1$) y mayor a 1 ($CG > 1$).

Tabla 9.-Valores del índice de mejoramiento de contraste con diferentes técnicas

Imagen/Técnica	CG<1	CG>1	EQH
MamoCC(D)	0.6401	1.4700	0.7623
MamoCC(I)	0.6525	1.4597	0.8083
MamoMLO(D)	0.7182	1.2977	0.9014
MamoMLO(I)	0.7183	1.3209	0.9460

Se observa valores de EQH y valores menores - mayores de CG con referencia a al valor 1 relacionados a imágenes : Mamo CC(D), CC (I), MLO (D) Y MLO (I).






Figura 27. Grafica de comparación de las diferentes técnicas de realce de contraste experimentadas.

Se utilizaron estas técnicas para realzar el contraste, lograr contornos más nítidos, resaltar detalles importantes como son las microcalcificaciones y seguir preparando la información para los procesos posteriores.

Las técnicas de corrección gamma definida por la ley de potencias ($ImagenSalida = (ImagenEntrada)^\gamma$), cuando $\gamma < 1$ se produce compresión y en el caso cuando $\gamma > 1$ se produce expansión, con lo que el contraste aumenta.

En el caso de la ecualización del histograma se trata de obtener para una imagen un histograma con una distribución uniforme el mismo número de pixeles para cada nivel de gris del histograma de una imagen monocroma, consiguiéndose maximizar el contraste sin perder información estructural, esto es, conservando su entropía.

Luego de observar y comparar resultados, el de mejor respuesta para reforzar el contraste de la imagen es el de corrección gamma > 1 seguido de la ecualización del histograma.




Con los resultados anteriores se utilizan los de mejor respuesta. Se unifican todas las técnicas y algoritmos: Utilizando el filtro de la mediana se aplicó la transformada top hat doble para lograr subsegmentar la imagen tratando de aislar las microcalcificaciones. Luego aplicamos la corrección $\gamma > 1$, la ecualización del histograma, la umbralización por el método de Otsu y se remueven objetos menores a 8 (según experimentación con la imagen phantom siendo este paso opcional), para lograr finalmente segmentar o aislar las microcalcificaciones.


A continuación se muestra el código con la que implementa las técnicas y algoritmos experimentados para lograr segmentar las microcalcificaciones:

```
[fname, path]=uigetfile('*.jpg','Select on Image');% ventana de dialogo para abrir un
fichero
fname=strcat(path,fname);
imOrig=imread(fname);% se asigna una variable para la imagen seleccionada
image(1),imshow(imOrig),title('imagen original');
E2=imcrop;% recorte o reducción de área
E=medfilt2(E2);% filtro de la mediana
se=strel('ball',8,50);% aplicamos la transformada top hat doble
T1=imtophat(E,se);
T=imtophat(T1,se);
T=double(T).^1.2;% correccion gamma
T=uint8(T);
S=adapthisteq(T,'Cliplimit',0.02); % aplicamos una ecualizacion adaptativa
level=graythresh(S); % umbralizacion utilizando el método de otsu
bw=im2bw(S,level);
B=bwareaopen(bw,8);% quitamos objetos de menos de 8 pixeles cuadrados según
experimentación
figure(2),subplot(1,2,1),imshow(E2),title('imagen
recortada'),subplot(1,2,2),imshow(B),title('imagen segmentada');
```





(a)



(b)

Figura 28. (a) y (b): Resultado después de recortar, procesar y segmentar la imagen de entrada, quedando aisladas totalmente las microcalcificaciones.

Luego se experimenta modificando la longitud del radio del elipsoide o elemento estructurante de la transformada top hat (de 8 a 4 píxeles) pero modificando la altura del elipsoide (de 50 a 35) se obtuvo mejores resultados de segmentación, y finalmente omitiendo la función “bwareaopen” (opcional) el proceso de segmentación queda de la siguiente manera:



```
[fname, path]=uigetfile('*.jpg','Select on Image');
fname=strcat(path,fname);
imOrig=imread(fname);
image(1),imshow(imOrig),title('imagen original');
A1=imcrop;
if size(A1,3)==3;
    A2=rgb2gray(A1);
else
    A2=A1;
end
A2=medfilt2(A2);
%aplicamos la transformada top hat
se=strel('ball',8,35);
T1=imtophat(A2,se);
T=imtophat(T1,se);
T=double(T).^1.2;%aplicamos la correccion gamma
T=uint8(T);
%aplicamos una ecualizacion adaptativa
S=adapthisteq(T,'Cliplimit',0.02);
%umbralizacion utilizando el método de otsu
level=graythresh(S);
bw=im2bw(S,level);
%quitamos objetos de menos de 8 pixeles cuadrados
%B=bwareaopen(bw,4);%opcional

figure(2),imshow(bw),title('imagen segmentada');
```




Figura 29. Imagen final segmentada con parámetros de mejor respuesta.

Para la etapa de extracción de características, los cálculos se realizan enseguida con los algoritmos de procesamiento y segmentación en la implementación final.

Luego se implementa la dataset de entrenamiento de imágenes tanto benignas (9) como sospechosas (9) validadas por Médicos Radiólogos, luego de aplicar reducción de área y todas las técnicas y algoritmos de filtrado, realce de contraste y segmentación, se crea el cell con los descriptores (tanto de forma-localización e intensidad) de todas estas imágenes.

En Matlab finalmente con la función `csvwrite`, se crea un archivo llamado 'ArchivoCSVEntren', con formato CSV (valores separados por coma).

Este archivo que contiene los vectores o descriptores y es ingresado a la red neuronal de Neuroph Studio, obteniéndose los siguientes resultados.

Resultados del entrenamiento de la red neuronal con Neuroph Studio

El entrenamiento se realizó con las 9 imágenes benignas y 9 sospechosas que se enumeraron en el data set de entrenamiento y con opinión médica de especialistas radiólogos.




Figura 30. Error del 2% que alcanzo la red entrenada en un comienzo.



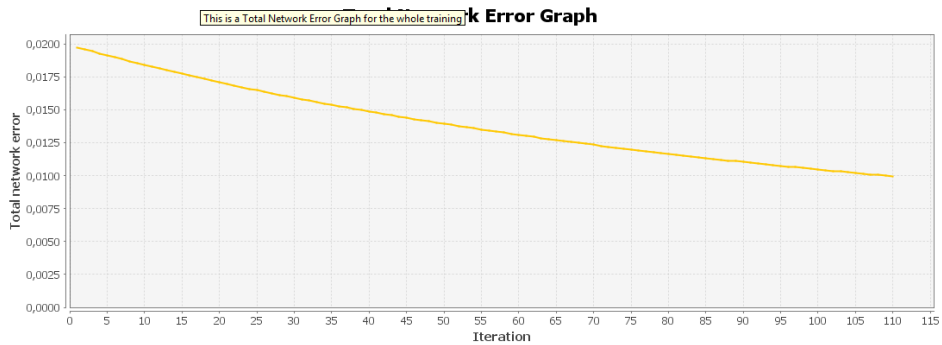


Figura 31. Error del 1% que alcanzo finalmente la red neuronal

Luego de entrenada la red se realizó un test de la red con 6 imágenes benignas y 6 imágenes sospechosas, obteniéndose los siguientes resultados:

```

Confusion matrix:
  True False
True  5  1
False 0  6

Classification metrics
Class: True
Total items: 12.0
True positive:5.0
True negative:6.0
False positive:0.0
False negative:1.0
Accuracy (ACC): 0.9166666666666666
Sensitivity or true positive rate (TPR): 0.8333333333333334
Specificity (SPC) or true negative rate (TNR): 1.0
Fall-out or false positive rate (FPR): 0.0
False negative rate (FNR): 0.166666666666666666
Precision or positive predictive value (PPV): 1.0
Recall: 0.8333333333333334
F-measure: 0.9090909090909091
False discovery rate (FDR): 0.0
Matthews correlation Coefficient (MCC): 0.8451542547285166

Stats{accuracy=0.9166666666666666, precision=1.0, recall=0.8333333333333334, fScore=0.9090909090909091, merror=0.0, corelationCoefficient=0.0}
    
```

Figura 32. Resultado del clasificador con data set de prueba.






Figura 33. Curva ROC obtenida después de pasar la data set de prueba

Tabla 10. Llenado de datos con la matriz confusión

		PREDICCIÓN	
		POSITIVOS	NEGATIVOS
DATO REAL	POSITIVOS	VERDADEROS POSITIVOS(TP)=5	FALSO NEGATIVO(FN)=1
	NEGATIVOS	FALSO POSITIVO (FP)=0	VERDADEROS NEGATIVOS(TN)=6

Se observa en la tabla datos de los resultados del data set de prueba

A continuación se calculan las métricas para determinar el desempeño del clasificador:

ESPECIFICIDAD= $TN / (TN + FP) = 6 / (6 + 0) = 9 / 9 = 1 (100\%)$,

SENSIBILIDAD= $TP / (TP + FN) = 5 / (5 + 1) = 0.83 (83\%)$, EXACTITUD= $(TN + TP) / TOTAL = (6 + 5) / 12 = 0.91 (91\%)$,

TASA DE ERROR= $(FP + FN) / TOTAL = (0 + 1) / 12 = 0.083 (8.3\%)$ y PRECISION= $TP / (TP + FP) = 5 / (5 + 0) = 1 (100\%)$



Finalmente se diagrama la curva ROC y el área bajo la curva AUC:




Figura 34. Area bajo la curva del clasificador neuronal (AUC).

$AUC = \int_0^1 ROC(t) dt = [1 - (0.33 * 0.5) / 2] = 0.917$ (según datos de la figura 33, obtenida en Neuroph Studio)

Un discriminador debe tener un valor comprendido en el rango de 0.5 y 1. En nuestro caso es de 0.91, pero lo ideal debería tender a 1.



3.2..Modelo utilizado para llegar a los resultados

El modelo que desarrollo en este proyecto, dadas las características del problema, se ajusta a un sistema de detección o identificación de microcalcificaciones (CAD), y se compone de las siguientes fases citadas.

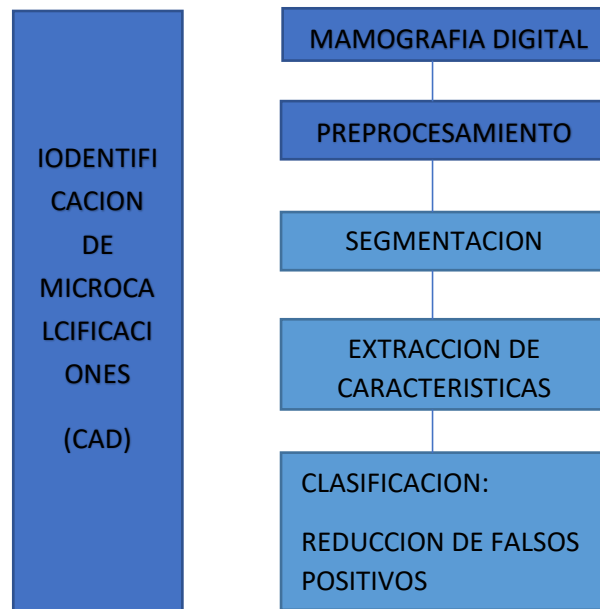


Figura 35. Modelo de la propuesta de investigación

Las imágenes digitales que se utilizan en esta investigación están conformadas por los casos clínicos de reportes de pacientes con biopsia en la unidad de diagnóstico por imágenes del Hospital Nacional Almanzor Aguinaga Asenjo de Chiclayo (Essalud) y periferia, en especial de los años 2017-18-19.

La mamografía digital es obtenida de un mamografo o mastografo, existiendo dos sistemas:

El primero se llama mamografía digital indirecta o CR y utiliza una pantalla o placa de fosforo que se carga eléctricamente luego del disparo o exposición de rayos x, un haz laser enseguida estimula la placa de fosforo y crea una luminiscencia proporcional a la exposición de rayos x local. La luminiscencia es capturada por un PMT (Photo Multiplier Tube), digitalizada y procesada formándose la imagen digital de la mama.

El segundo se llama mamografía digital directa (actualmente llamada tomosíntesis), porque los rayos x atraviesan la mama y generan la imagen digital de manera directa, la



misma que puede ser almacenada en una base de datos, procesada digitalmente y/o transferida por red a otros usuarios.

En el caso del primer sistema el digitalizador mayormente usado en Essalud es el de marca Konica Minolta y según especificaciones:

Reading resolution

Standar mode: 175 μm , High resolution mode 87.5 μm

High resolution mammo mode: 43.75 μm .

Digital tone steps

12 bit (4096 steps)

La adquisición de las imágenes mamográficas son obtenidas de un mamógrafo: dos con proyección cráneo caudal (CC) y dos con proyección medio lateral oblicua a 45° (MLO) tanto a la mama derecha como a la izquierda. En el caso de la tomosíntesis se adquieren una secuencia de imágenes en ambas proyecciones.

Teniendo ya las imágenes enseguida se realizó un recorte para obtener parte de la imagen que es de interés (ROI), luego se experimentó distintas técnicas y algoritmos de preprocesamiento con la herramienta Matlab, para la reducción de ruido con diferentes filtros a través de convoluciones y distintos kernels o núcleos de convolución.

Se experimentó también los operadores basados en la primera derivada (gradiente) y segunda derivada (Laplaciano) de las variaciones de los niveles de gris, así también con el filtro no lineal de la mediana, con el que se obtuvo mejores resultados.

Para realizar o mejorar el contraste se experimentan técnicas de ecualización y de corrección gamma.

Teniendo la imagen ya procesada se prosigue con la segmentación, cuyo objetivo principal es identificar regiones sospechosas, es decir, regiones con presencia de alguna anomalía del tipo microcalcificación. El objetivo es dividir la imagen en objeto y fondo, considerando como objeto a las regiones que contengan microcalcificaciones y como fondo al resto de regiones de la imagen.

Las técnicas de segmentación que experimente son la morfología matemática y la umbralización por el método de otsu.

Finalmente en el módulo de clasificación de objetos se propone utilizar una red neuronal para toma de decisión, para decidir a qué categoría pertenece cada objeto.

3.2.-Realización de la metodología propuesta para la investigación.

3.2.1.-Utilización de diferentes técnicas y algoritmos de filtrado, así como métricas para evaluar la efectividad de estas, eligiéndose el más eficiente.

A continuación se muestra el algoritmo para la aplicación de los diferentes filtros experimentados:

Inicio

DATOS

Variables: Búsqueda y selección de imagen en formato JPG, Filtro, Kernel o núcleo de convolucion, Imagen final o procesada.

ALGORITMO

Cargar imagen de entrada.

Recorte o reducción de área (imagen de la region de interes)

Conversión a escala de grises

Implementación de una función para filtrado con 2 argumentos: imagen y kernel o núcleo de convolucion

Calcular MSE (error cuadrático medio) y PSNR (relación señal-ruido)

Mostrar imagen procesada.

Leer datos calculados.

Fin

A continuación se utiliza el Algoritmo para aplicar las diferentes técnicas de filtrado calculando al mismo tiempo las métricas para determinar la efectividad: Error cuadrático medio (MSE) y relación señal ruido pico (PSNR).



```
[fname, path]=uigetfile('*.*jpg','Select on Image');%ventana de dialogo para abrir un
fichero
fname=strcat(path,fname);
A2=imread(fname);%se asigna una variable para la imagen seleccionada
figure(1),imshow(A2);axis image
A2=imcrop;%recorte o reducción de área
A2=rgb2gray(A2);%convierte imagen RGB o colores a escala de grises
HB1=[1 1 1 1 1, 1 1 1 1 1, 1 1 1 1 1, 1 1 1 1 1,1 1 1 1 1]/25;%núcleo de
convolucion para el filtro box de 5x5(llamado también filtro de promedio)
FiltroBox=imfilter(A2,HB1);%filtrado de imagen con dos argumentos:
la imagen a filtrar y el núcleo de convolucion
H=[0 1 2 1 0,1 3 5 3 1,2 5 9 5 2,1 3 5 3 1,0 1 2 1 0]/57;%núcleo de
convolucion para el filtro de suavizado gaussiano
kernelGradiente=[0 -1 0; 0 0 0;0 1 0];
kernelLaplaciano=[0 1 0;1 -4 1;0 1 0];
FiltroGauss=imfilter(A2,H);%filtrado de imagen con dos argumentos:
la imagen a filtrar y el núcleo de convolucion
FiltroGradiente=imfilter(A2,kernelGradiente);
FiltroLaplaciano=imfilter(A2,kernelLaplaciano);
FiltroMediana=medfilt2(A2); %realiza el filtrado de la mediana .Cada píxel de salida
contiene el valor medianoen una vecindad de 3 por 3 alrededor del píxel
correspondiente
en la imagen de entrada.
figure(2),subplot (1,5,1),imshow(FiltroBox),title('filtro box'),
subplot (1,5,2),imshow(FiltroGauss),title('filtro gaussian'),
subplot (1,5,3),imshow(FiltroMediana),title('filtro mediana'),
subplot (1,5,4),imshow((FiltroGradiente)*10),title('filtro gradiente o de 1er orden'),
subplot (1,5,5),imshow((FiltroLaplaciano)*10),title('filtro laplaciano o de 2do orden'),
MSE1=ErrorCuadMedio (A2,FiltroBox);%mide la diferencia entre la imagen
original y la imagen filtrada o procesada
MaxI=255;% the maximum possible pixel value of the images.
PSNR1=10*log10((MaxI^2)/MSE1);%relación pico señal a ruido,
que indica un buen desempeño de la técnica entre más alta sea su magnitud.
MSE2=ErrorCuadMedio(A2,FiltroGauss);
PSNR2=10*log10((MaxI^2)/MSE2);
MSE3=ErrorCuadMedio(A2,FiltroMediana);
PSNR3=10*log10((MaxI^2)/MSE3);
MSE4=ErrorCuadMedio(A2,FiltroGradiente);
PSNR4=10*log10((MaxI^2)/MSE4);
MSE5=ErrorCuadMedio(A2,FiltroLaplaciano);
PSNR5=10*log10((MaxI^2)/MSE5);
```






Figura 36. Imágenes con filtro box (kernel de 5x5) o de media, filtro Gaussiano, filtro de la mediana, filtro gradiente y filtro laplaciano.

3.2.2.-Utilizacion de diferentes técnicas y algoritmos de realce de contraste, así como métricas para evaluar la efectividad de estas, eligiéndose el más eficiente.

A continuación se muestra el algoritmo para la aplicación de técnicas de realce de contraste:

Inicio

DATOS

Variables: Búsqueda y selección de imagen en formato JPG, Funcion especifica de realce de contraste, Imagen final o procesada.

ALGORITMO

Cargar imagen de entrada.

Recorte o reducción de área (imagen de la region de interes)

Conversión a escala de grises

Implementación de transformación local o una función específica para realce de contraste a la imagen de entrada.

Calcular Indice de mejoramiento de contraste (CII)

Mostrar imagen procesada.

Leer datos calculados.

Fin



Luego se utiliza el Algoritmo para aplicar las diferentes técnicas calculando al mismo tiempo las métricas para determinar la efectividad: Índice de realce de contraste de la imagen mejorada con respecto a la original(Contrast Improvement Index-CII).

```
[fname, path]=uigetfile('*.jpg','Select on Image');
fname=strcat(path,fname);
A1=imread(fname);%carga de la imagen original
figure(1),imshow(A1);axis image
A2=imcrop;%imagen original recortada
bw=rgb2gray(A2);
bw=double(bw);
bw=bw/255;
bw1=bw.^0.5;%imagen gamma<1
bw1=bw1*255;
bw1=uint8(bw1);
bw2=bw.^1.5;%imagen gamma>1
bw2=bw2*255;
bw2=uint8(bw2);
EQH=adapthisteq( rgb2gray(A2),'ClipLimit',0.02);%Ecuación de
histograma adaptativo con contraste limitado
%despliegue
figure(1),subplot(1,3,1),imshow(bw1),title('gamma<1'),
subplot(1,3,2),imshow(bw2),title('gamma >1'),
subplot(1,3,3),imshow(EQH),title('EQH');
%cálculo del índice de realce de contraste
ContrGamma1=PromValorGris(bw1);%Contraste de la imagen equalizada <1
ContrGamma2=PromValorGris(bw2);%Contraste de la imagen equalizada >1
ContrEQH=PromValorGris(EQH);
ContrOrig=PromValorGris(A2);%Contraste de la imagen original
CII1=ContrOrig/ContrGamma1;%Índice de realce de contraste de la imagen
mejorada con respecto a la original(Contrast Improvement Index)
CII2=ContrOrig/ContrGamma2;%Índice de realce de contraste de la imagen
mejorada con respecto a la original(Contrast Improvement Index)
CII3=ContrOrig/ContrEQH;
```






Figura 37. Imagen procesada con 3 diferentes técnicas de realce de contraste

3.2.3.-Implementacion de la transformada tophat como una subsegmentacion para identificar las microcalcificaciones dentro de la imagen digital mamográfica.

Algoritmo para la aplicación de la transformada Top Hat:

Inicio

DATOS

Variables: Imagen original de entrada, Imagen final o procesada.

ALGORITMO

Cargar imagen de entrada.

Selección del elemento estructurante.

Primera aplicación de la función top hat, cuyos argumentos son la imagen de entrada y el elemento estructurante seleccionado.

Segunda aplicación de la función top hat, con los mismos argumentos anteriores

Mostrar imagen procesada.

Observación y comparación de imágenes.

Fin

Se aplica el algoritmo para subsegmentar las microcalcificaciones:


```
[fname, path]=uigetfile('*.jpg','Select on Image');
fname=strcat(path,fname);
imOrig=imread(fname);
figure(1),imshow(imOrig);axis image
igray=imcrop;
igray=rgb2gray(igray);
A2=medfilt2(igray);% filtro no lineal de la mediana
se1=strel('ball',8,50);
imtop=imtophat(A2,se1);% transf. tophat,para resaltar detalles claros en la presencia de
sombras (pequeños detalles brillantes)
imtop1=double(imtop);
a2=imtop1.^1.3;
a2=uint8(a2);%mejoramiento del contraste con correccion gamma>1.
se2=strel('disk',8);
imtop3=imtophat(A2,se2);% transf. tophat,para resaltar detalles claros en la presencia de
sombras (pequeños detalles brillantes)
imtop3=double(imtop3);
a3=imtop3.^1.3;
figure(2),
subplot(1,3,1),imshow(uint8(imOrig)),title('imagen original recortada'),
subplot(1,3,2),imshow(a2),title('Subsegment doble TOP HAT(se:ball)');
subplot(1,3,3),imshow(uint8(a3)),title('Subsegment TOP HAT(se:disk)');
```






Figura 38. Aplicación de la transformada tophat a una imagen mamográfica con 2 diferentes elementos estructurantes.





(a)



(b)

Figura 39.(a) Elemento estructural no lineal ‘ball-shaped’ (elipsoide) y (b) su curva no lineal de reforzamiento

Por ejemplo el caso de R=4 y H=50, Matlab lo define así:

```

Neighborhood:
0 0 1 1 1 1 1 1 1 0 0
0 1 1 1 1 1 1 1 1 1 1
1 1 1 1 1 1 1 1 1 1 1
1 1 1 1 1 1 1 1 1 1 1
1 1 1 1 1 1 1 1 1 1 1
1 1 1 1 1 1 1 1 1 1 1
1 1 1 1 1 1 1 1 1 1 1
1 1 1 1 1 1 1 1 1 1 1
1 1 1 1 1 1 1 1 1 1 1
0 1 1 1 1 1 1 1 1 1 0
0 0 1 1 1 1 1 1 1 0 0

Height:
-Inf -Inf 0 6.2484 12.4969 18.7453 12.4969 6.2484 0 -Inf -Inf
-Inf 6.2484 12.4969 18.7453 24.9937 24.9937 24.9937 18.7453 12.4969 6.2484 -Inf
0 12.4969 18.7453 24.9937 31.2421 31.2421 31.2421 24.9937 18.7453 12.4969 0
6.2484 18.7453 24.9937 31.2421 37.4906 37.4906 37.4906 31.2421 24.9937 18.7453 6.2484
12.4969 24.9937 31.2421 37.4906 43.7390 43.7390 43.7390 37.4906 31.2421 24.9937 12.4969
18.7453 24.9937 31.2421 37.4906 43.7390 49.9874 43.7390 37.4906 31.2421 24.9937 18.7453
12.4969 24.9937 31.2421 37.4906 43.7390 43.7390 43.7390 37.4906 31.2421 24.9937 12.4969
6.2484 18.7453 24.9937 31.2421 37.4906 37.4906 37.4906 31.2421 24.9937 18.7453 6.2484
0 12.4969 18.7453 24.9937 31.2421 31.2421 31.2421 24.9937 18.7453 12.4969 0
-Inf 6.2484 12.4969 18.7453 24.9937 24.9937 24.9937 18.7453 12.4969 6.2484 -Inf
-Inf -Inf 0 6.2484 12.4969 18.7453 12.4969 6.2484 0 -Inf -Inf
    
```

Figura 40. Elemento estructural ball shaped definido por Matlab



3.2.4.-Resultados en la segmentacion utilizando técnicas de umbralizacion

Se utilizó el método de otsu, como una técnica de segmentación final debido a que se tiene dos clases bien diferenciadas entre el objeto microcalcificacion y el fondo o tejido mamario.


En las primeras experimentaciones se probó con una umbralizacion manual, eligiendo un umbral adecuado pero la información diagnostica en la imagen digital es distinta entre una y otra imagen. El método otsu es un procedimiento que selecciona el umbral óptimo maximizando la varianza entre clases mediante una búsqueda avanzada.

3.2.5.-Resultados experimentales utilizando la imagen del Phantom como patrón para encontrar el área mínima posible de las microcalcificaciones




Figura 41. Phantom o maniquí (utilizado para control de calidad de equipos de mamografía), utilizándolo en esta investigación como imagen patrón para encontrar el área mínima posible de las microcalcificaciones

Es un equivalente de cera y acrílico a 4.2 cm de espesor de tejido mamario comprimido: 50% adiposo y 50% glandular. Contiene los siguientes objetos: 6 fibras de 1.56, 1.12, 0.89, 0.75, 0.54 y 0.4 mm; 5 grupos de microcalcificaciones con diámetros 0.54, 0.4, 0.32, 0.24 y 0.16 mm y 5 masas de 2.00, 1.00, 0.75, 0.5 y 0.25 mm.



(a)



(b)

Figura 42. (a) El phantom contiene: 6 fibrillas de nylon, 5 grupos de microcalcificaciones y 5 masas. Sus dimensiones (L/W/h): 10.2x10.8x4.5 cm. (b) Imagen obtenida del phantom.

Aplicamos técnicas y algoritmos para determinar el área mínima de las microcalcificaciones presentes en las imágenes digitales de mamografía que se pueden detectar, eligiendo a un phantom como imagen patrón. El argumento modificable (área) se cambia en la función “bwareaopen (img,área)”.



Inicio

DATOS

Variables: Búsqueda y selección de imagen en formato JPG, Imagen final o procesada.

ALGORITMO

Cargar imagen de prueba phantom

Recorte o reducción de área (imagen de la region de interes)

Conversión a escala de grises

Se aplica el filtro de la mediana

Se aplica la transformada Top Hat con dos diferentes elementos estructurantes.

Aplicamos una ecualizacion adaptativa

Umbralizacion utilizando el método de otsu

Quitamos objetos de menos de 30, 20 y 8 pixeles cuadrados secuencialmente.

Mostrar imagenes procesadas

Fin

Luego utilizamos el algoritmo en Matlab:

```
[fname, path]=uigetfile('*.jpg','Select on Image');
fname=strcat(path,fname);
A=imread(fname);
figure(1),imshow(A),title('Imagen de entrada');
E2=imcrop;
E1=rgb2gray(E2);
E=medfilt2(E1);
%aplicamos la transformada
se=strel('ball',8,50);
T1=imtophat(E,se);
T=imtophat(T1,se);
T=double(T).^1.2;
T=uint8(T);
%aplicamos una ecualizacion adaptativa
S=adapthisteq(T,'Climlimit',0.02);
%umbralizacion utilizando el método de otsu
level=graythresh(S);
bw=im2bw(S,level);
%quitamos objetos de menos de 8 pixeles cuadrados
B=bwareaopen(bw,30-20-8);
imshow(B);
```

Resultados para la determinación del área mínima que el algoritmo puede detectar de las microcalcificaciones segmentadas:






Figura 43. Resultado inicial para hallar el área mínima detectable de la microcalcificaciones utilizando la imagen del phantom (de detectan microcalcificaciones en el grupo 7 y 8 de 0.52 y 0.4 mm)

Después de experimentar modificando los parámetros de la transformada top hat se concluye que la altura del elipsoide es la que determina el área mínima que puede ser detectada por el algoritmo, observándose algunas microcalcificaciones del grupo 9 del phantom de 0.32 mm.

```
[fname, path]=uigetfile('*.jpg','Select on Image');
fname=strcat(path,fname);
imOrig=imread(fname);
image(1),imshow(imOrig),title('imagen original');
A1=imcrop;
if size(A1,3)==3;
    A2=rgb2gray(A1);
else
    A2=A1;
end
A2=medfilt2(A2);
se2=strel('ball',8,35);
T=imtophat(A2,se2);
T=imtophat(T,se2);
T=double(T).^1.2;%aplicamos la correccion gamma
T=uint8(T);
%aplicamos una ecualizacion adaptativa
S=adapthisteq(T,'Cliplimit',0.02);
%umbralizacion utilizando el metodo de otsu
level=graythresh(S);
bw=im2bw(S,level);
%quitamos objetos de menos de 8 pixeles cuadrados
% B=bwareaopen(bw,8);%opcional

figure(2),imshow(bw),title('imagen segmentada');
```




Figura 44. El sistema logra detectar 3 grupos: Un grupo de 0.54 mm(6/6), otro de 0.4(6/6) y dos microcalcificaciones del grupo de 0.32mm(2/6).

A continuación se muestra la utilización de todos los algoritmos experimentados en Matlab para finalmente segmentar y también obtener los vectores de características de la data set de entrenamiento en un archivo con formato csv:

```
%lectura de imagenes en directorios y creacion de un cell

lecturaImagenes1 = dir('C:\Users\RAUL\Documents\MATLAB\Nueva
carpeta\Imagenes Mamograficas Normales\*.jpg');

imagenes1=length(lecturaImagenes1);
lecturaImagenes2 = dir('C:\Users\RAUL\Documents\MATLAB\Nueva
carpeta\Imagenes Mamograficas Sospechosas\*.jpg');
imagenes2=length(lecturaImagenes2);
%crear cell
datos=cell(5,imagenes1+imagenes2);
%leemos todo el directorio y llenamos la fila 1 del cell
for k=1:imagenes1

    char1=lecturaImagenes1(k).name;
char2='C:\Users\RAUL\Documents\MATLAB\Nueva carpeta\Imagenes
Mamograficas Normales\';
file=[char2 char1];
datos{2,k}=importdata(file);
datos{1,k}='benign';

end

for k=1:imagenes2
char2=lecturaImagenes2(k).name;
    char3='C:\Users\RAUL\Documents\MATLAB\Nueva carpeta\Imagenes
Mamograficas Sospechosas\';
    file1=[char3 char2];
```




```

datos{2,k+imagenes1}=importdata(file1);
datos{1,k+imagenes1}='sospechoso';
end

for k=1:imagenes1+imagenes2
%desde 1 hasta número de imagenes total repetimos la top hat
%extraemos la imagen E2 de la fila 1 del cell
    E2=datos{2,k};
figure(1),imshow(E2);axis image
    E2=imcrop;
%E2=rgb2gray(E2);
    E=medfilt2(E2);
%aplicamos la transformada top hat
se=strel('ball',8,35);
    T1=imtophat(E,se);
    T=imtophat(T1,se);
    T=double(T).^1.2;%aplicamos la correccion gamma
    T=uint8(T);
%aplicamos una ecualizacion adaptativa
    S=adapthisteq(T,'ClipLimit',0.02);
%umbralizacion utilizando el método de otsu
level=graythresh(S);
bw=im2bw(S,level);
%quitamos objetos de menos de 8 pixeles cuadrados según
experimentacion
    %B=bwareaopen(bw,8);%opcional
%guardamos en la tercera fila del cell la imagen B
datos{3,k}=B;
%cálculo de descriptores
datos{4,k}=regionprops(logical(B),'all');
end

M=zeros(imagenes1 + imagenes2,39);

for k=1:(imagenes1+imagenes2)
%cálculo de descriptores de forma y localizacion
    Ar=[datos{4,k}.Area];
datos{5,k}.NumeroCalcificaciones=length(Ar);%1.Numero de
Microcalcificaciones

datos{5,k}.AreaMedia=sum(Ar)/datos{5,k}.NumeroCalcificaciones;%2.Area
Media
datos{5,k}.AreaMax=max(Ar);%3.Area Maxima
datos{5,k}.AreaMin=min(Ar);%4.Area Minima
    datos{5,k}.AreaRelativa=(max(Ar) -
min(Ar))/datos{5,k}.AreaMedia;%5.Area Relativa
    Ec=[datos{4,k}.Eccentricity];

datos{5,k}.ExcentricMedia=sum(Ec)/datos{5,k}.NumeroCalcificaciones;%6.E
xcentricidad Media
datos{5,k}.ExcentricMax=max(Ec);%7.
datos{5,k}.ExcentricMin=min(Ec);%8.
    datos{5,k}.ExcentricRel=(max(Ec) -
min(Ec))/datos{5,k}.ExcentricMedia;%9
    Ma=[datos{4,k}.MajorAxisLength];

datos{5,k}.MayorEjeMedia=sum(Ma)/datos{5,k}.NumeroCalcificaciones;%10

```



```

datos{5,k}.MayorEjeMax=max(Ma);%11
datos{5,k}.MayorEjeMin=min(Ma);%12
    datos{5,k}.MayorEjeRel=(max(Ma)-
min(Ma))/datos{5,k}.MayorEjeMedia;%13
    Mi=[datos{4,k}.MinorAxisLength];

datos{5,k}.MinorEjeMedia=sum(Mi)/datos{5,k}.NumeroCalcificaciones;%14
datos{5,k}.MinorEjeMax=max(Mi);%15
datos{5,k}.MinorEjeMin=min(Mi);%16
    datos{5,k}.MinorEjeRel=(max(Mi)-
min(Mi))/datos{5,k}.MinorEjeMedia;%17

    Ed=[datos{4,k}.EquivDiameter];

datos{5,k}.DiametroMedia=sum(Ed)/datos{5,k}.NumeroCalcificaciones;%18
datos{5,k}.DiametroMax=max(Ed);%19
datos{5,k}.DiametroMin=min(Ed);%20
    datos{5,k}.DiametroRel=(max(Ed)-
min(Ed))/datos{5,k}.DiametroMedia;%21

    Sd=[datos{4,k}.Solidity];

datos{5,k}.SolidezMedia=sum(Sd)/datos{5,k}.NumeroCalcificaciones;%22
datos{5,k}.SolidezMax=max(Sd);%23
datos{5,k}.SolidezMin=min(Sd);%24
    datos{5,k}.SolidezRel=(max(Sd)-
min(Sd))/datos{5,k}.SolidezMedia;%25

    Pe=[datos{4,k}.Perimeter];

datos{5,k}.PerimeterMedia=sum(Pe)/datos{5,k}.NumeroCalcificaciones;%26
datos{5,k}.PerimeterMax=max(Pe);%27
datos{5,k}.PerimeterMin=min(Pe);%28
    datos{5,k}.PerimeterRel=(max(Pe)-
min(Pe))/datos{5,k}.PerimeterMedia;%29
ce=[datos{4,k}.Centroid];
datos{5,k}.Centroide=mean(ce);%30

Ci=(4*pi*datos{5,k}.AreaMedia)/(datos{5,k}.PerimeterMedia*datos{5,k}.P
erimeterMedia);%circularidad
datos{5,k}.Circularidad=Ci;%31

elog=datos{5,k}.MinorEjeMedia/datos{5,k}.MayorEjeMedia;%elongacion
datos{5,k}.Elongacion=elog;%32

form=(datos{5,k}.PerimeterMedia*datos{5,k}.Elongacion)/(8*datos{5,k}.A
reaMedia);%forma
datos{5,k}.Forma=form;%33
%cálculo de descriptores de intensidad

med=PromValorGris(datos{3,k});
datos{5,k}.Media=med;%34.Media
    DesSt=DesviacionStd(datos{3,k});
datos{5,k}.DesvEstand=DesSt;%35.Desviacion Standar
skewns=Oblicuidad(datos{3,k});
datos{5,k}.Oblicuidad=skewns;%36.Oblicuidad
kurtos=Kurtos(datos{3,k});
datos{5,k}.Kurtosis=kurtos;%37.Kurtosis
minim=min(min(datos{3,k}));

```



```

datos{5,k}.Minimo=minim;%38.Minimo
maxim=max(max(datos{3,k}));
datos{5,k}.Maximo=maxim;%39.Maximo

%relleno de la matriz con los parámetros evaluados

M(k,1)=datos{5,k}.NumeroCalcificacions;
M(k,2)=datos{5,k}.AreaMedia;
M(k,3)=datos{5,k}.AreaMax;
M(k,4)=datos{5,k}.AreaMin;
M(k,5)=datos{5,k}.AreaRelativa;
M(k,6)=datos{5,k}.ExcentricMedia;
M(k,7)=datos{5,k}.ExcentricMax;
M(k,8)=datos{5,k}.ExcentricMin;
M(k,9)=datos{5,k}.ExcentricRel;
M(k,10)=datos{5,k}.MayorEjeMedia;
M(k,11)=datos{5,k}.MayorEjeMax;
M(k,12)=datos{5,k}.MayorEjeMin;
M(k,13)=datos{5,k}.MayorEjeRel;
M(k,14)=datos{5,k}.MinorEjeMedia;
M(k,15)=datos{5,k}.MinorEjeMax;
M(k,16)=datos{5,k}.MinorEjeMin;
M(k,17)=datos{5,k}.MinorEjeRel;
M(k,18)=datos{5,k}.DiametroMedia;

M(k,19)=datos{5,k}.DiametroMax;
M(k,20)=datos{5,k}.DiametroMin;
M(k,21)=datos{5,k}.DiametroRel;
M(k,22)=datos{5,k}.SolidezMedia;
M(k,23)=datos{5,k}.SolidezMax;
M(k,24)=datos{5,k}.SolidezMin;
M(k,25)=datos{5,k}.SolidezRel;

M(k,26)=datos{5,k}.PerimeterMedia;
M(k,27)=datos{5,k}.PerimeterMax;
M(k,28)=datos{5,k}.PerimeterMin;
M(k,29)=datos{5,k}.PerimeterRel;
M(k,30)=datos{5,k}.Centroide;
M(k,31)=datos{5,k}.Circularidad;
M(k,32)=datos{5,k}.Elongacion;
M(k,33)=datos{5,k}.Forma;
M(k,34)=datos{5,k}.Media;
M(k,35)=datos{5,k}.DesvEstand;
M(k,36)=datos{5,k}.Oblicuidad;
M(k,37)=datos{5,k}.Kurtosis;
M(k,38)=datos{5,k}.Minimo;
M(k,39)=datos{5,k}.Maximo;

end

Input1=M';
T2(1,10:18)=1;
Target=T2;%benigno=0,sospechoso=1
Input2=[Input1 ;Target];
Input=(Input2)';
csvwrite('ArchivoCSV',Input);%creamos un archivo con formato csv

```



3.2.6. Etapa de clasificación a base de una red neuronal




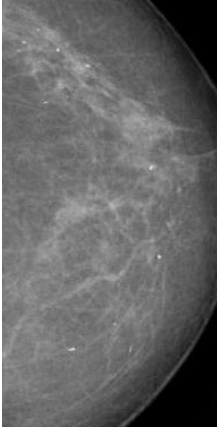
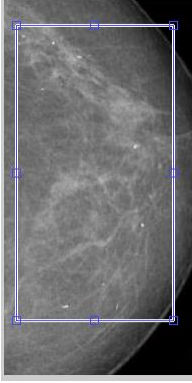
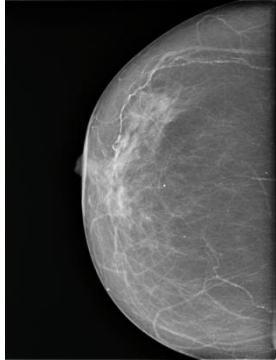
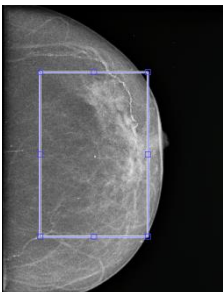
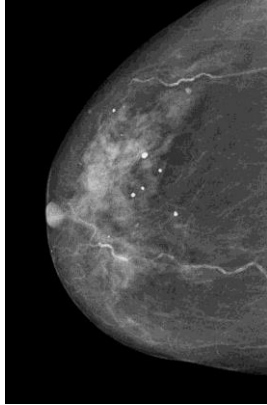
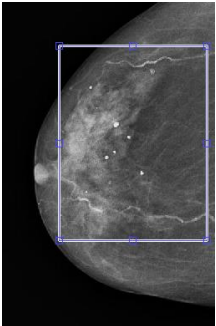
Figura 45. Red Neuronal que recibe los 39 descriptores de forma-localización y de intensidad, en sus neuronas de entrada y que clasificara las microcalcificaciones en benignos (0) o sospechosos (1).

3.2.7. Entrenamiento de la red neuronal como elemento clasificador de microcalcificaciones

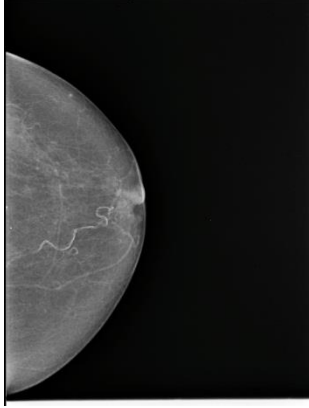
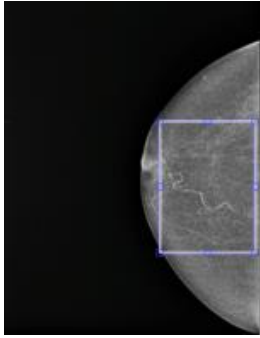
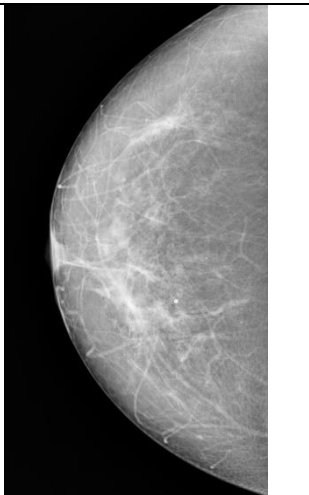
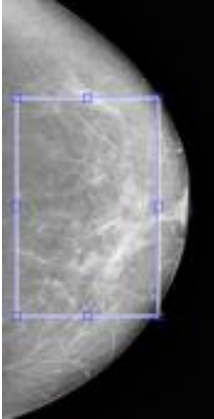
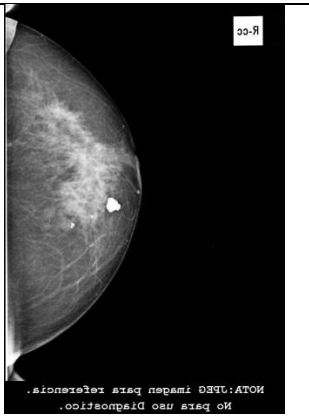
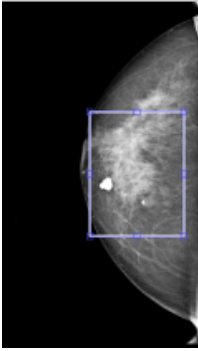
Para crear la data set de entrenamiento de la red neuronal se seleccionan 9 imágenes benignas y 9 imágenes sospechosas.



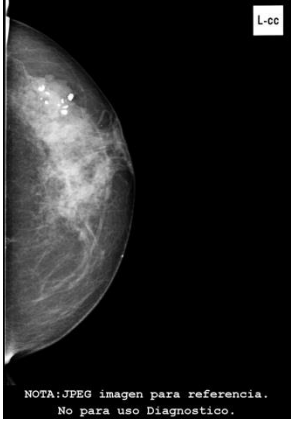
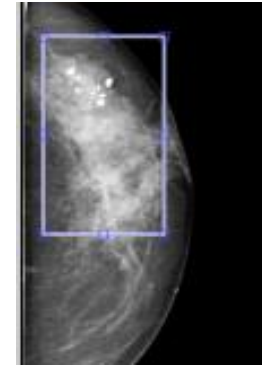

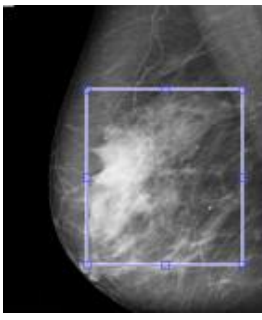


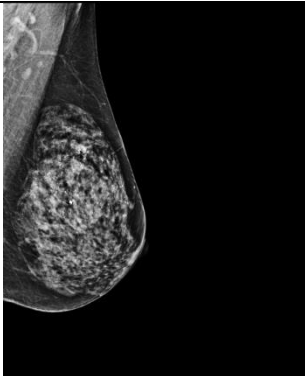
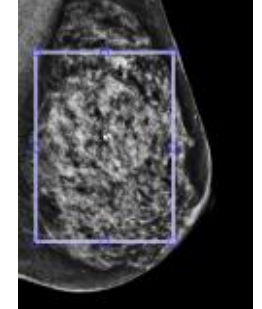
Tabla 11. Dataset etiquetado de imagenes digitales mamográficas construido para el entrenamiento del clasificador neuronal con neuroph estudio.

CODIGO	IMAGEN	ROI	Etiqueta	Comentario
1 Imagen- entrenamiento (benigna)1			Benigna (0)	Típicamente benigna, con algunas microcalcificacions redondas, puntiformes distribuidas difusamente por toda la mama (BIRADS 2).
2 Imagen- entrenamiento (benigna)2			Benigna (0)	Típicamente benigna, se observa algunas microcalcificaciones vasculares(BIRADS 2)
3 Imagen- entrenamiento (benigna) 3			Benigna (0)	Típicamente benigna, se observa algunas microcalcificacions vasculares, otras redondas y puntiformes (BIRADS 2)

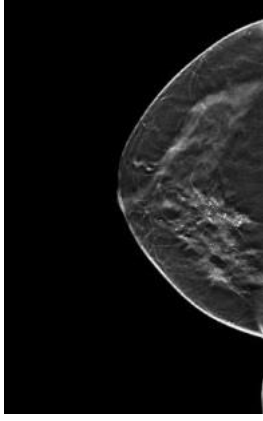
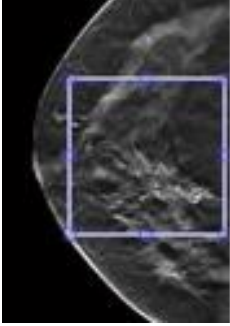
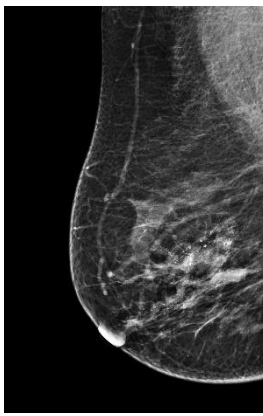
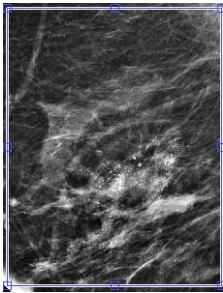
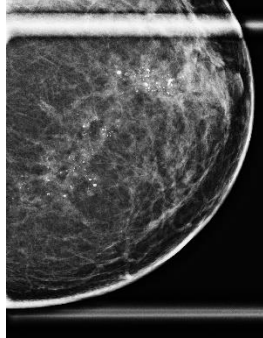
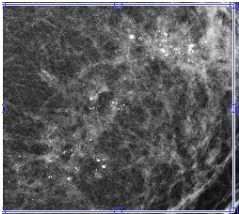
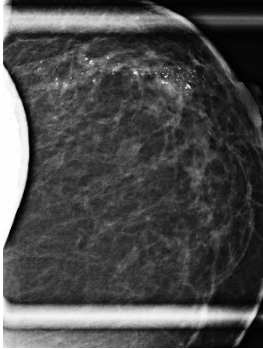
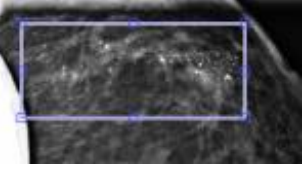



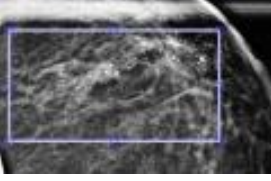
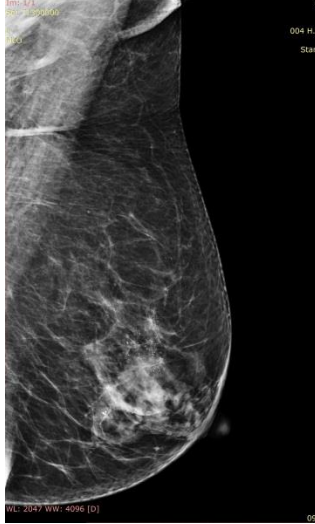
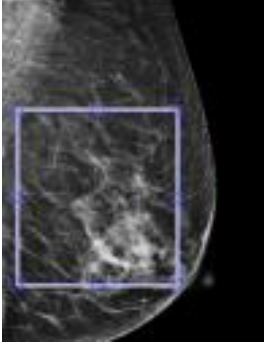
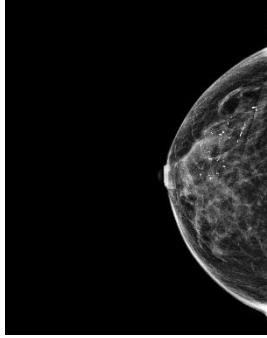
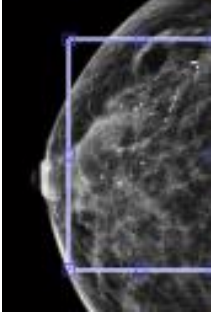
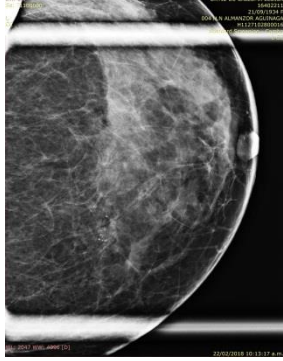
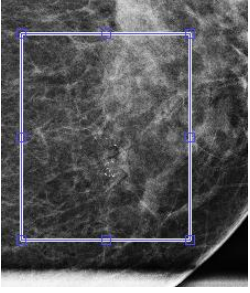
<p>4 Imagen- entrenamiento (benigna) 4</p>			<p>Benigna (0)</p>	<p>Típicamente benigna, se observa microcalcificaciones vasculares(BIRADS 2)</p>
<p>5 Imagen- entrenamiento (benigna) 5</p>			<p>Benigna (0)</p>	<p>Típicamente benigna, mama moderadamente densa, algunas microcalcificaciones puntiformes (BIRADS 2)</p>
<p>6 Imagen- entrenamiento (benigna) 6</p>			<p>Benigna (0)</p>	<p>Típicamente benigna, microcalcificacion pop corn o calcificación gruesa: fibroadenoma en involución. (BIRADS 2).</p>



<p>7 Imagen-entrenamiento (benigna) 7</p>			<p>Benigna (0)</p>	<p>Típicamente benigna, Calcificaciones gruesas, agrupadas. (BIRADS 2)</p>
<p>8 Imagen-entrenamiento (benigna) 8</p>			<p>Benigna (0)</p>	<p>Típicamente benigna, se observa mama moderadamente densa y con algunas microcalcificaciones (BIRADS 2)</p>
<p>9 Imagen-entrenamiento (benigna) 9</p>			<p>Benigna (0)</p>	<p>Típicamente benigna, se observa algunas microcalcificaciones vasculares(BIRADS 2)</p>
<p>10 Imagen-entrenamiento (sospechosa)1</p>			<p>Sospechosa (1)</p>	<p>Morfología sospechosa, se observan microcalcificaciones pleomorfas dispersas, (BIRADS 4).</p>



<p>11 Imagen- entrenamiento (sospechosa)2</p>			<p>Sospech osa (1)</p>	<p>Morfología sospechosa (Se observan microcalcificacions Pleomorficas, irregulares). BIRADS 4</p>
<p>12 Imagen- entrenamiento (sospechosa)3</p>			<p>Sospech osa (1)</p>	<p>Morfología sospechosa (Se observan microcalcificacions Pleomorficas finas, irregulares). BIRADS 4</p>
<p>13 Imagen- entrenamiento (sospechosa)4</p>			<p>Sospech osa (1)</p>	<p>Morfología sospechosa Se observa microcalcificaciones gruesas heterogéneas BIRADS 4</p>
<p>14 Imagen- entrenamiento (sospechosa)5</p>			<p>Sospech osa (1)</p>	<p>Microcalcificaciones gruesas heterogéneas BIRADS 4</p>

<p>15 Imagen-entrenamiento (sospechosa)6</p>			<p>Sospechosa (1)</p>	<p>Microcalcificacions heterogéneas, evidentes e irregulares BIRADS 4</p>
<p>16 Imagen-entrenamiento (sospechosa)7</p>			<p>Sospechosa (1)</p>	<p>Microcalcificaciones pleomorficas y lineales BIRADS 4C</p>
<p>17 Imagen-entrenamiento (sospechosa)8</p>			<p>Sospechosa (1)</p>	<p>Se observan microcalcificaciones lineales BIRADS 4</p>
<p>18 Imagen-entrenamiento (sospechosa)9</p>			<p>Sospechosa (1)</p>	<p>Se observa microcalcificaciones agrupadas e irregulares. BIRADS 4</p>

Dataset para entrenamiento de la red neuronal con lo que logra aprender las características de las microcalcificaciones.



Tabla 12. Tabla que resume los experimentos para el entrenamiento de la red neuronal con Framework Neuroph Studio.

Intento de entrenamiento	Cantidad de neuronas ocultas	Error Maximo	Tasa de aprendizaje	Numero de iteraciones	Funcion de Transferencia y learning	Red capacitada
1	10	0.01(1%)	0.2	50,000	Sigmoid-Backpropagation	No
2	10	0.02(2%)	0.2	40,000	Sigmoid-Backpropagation	No
3	10	0.04(4%)	0.2	30,000	Sigmoid-Backpropagation	No
4	10	0.06(6%)	0.2	Se entrenó inmediatamente	Sigmoid-Backpropagation	Si
5	20	0.01(1%)	0.2	110	Sigmoid-Backpropagation	Si

Intentos de entrenamiento y resultados de la red neuronal con neuroph studio experimentada

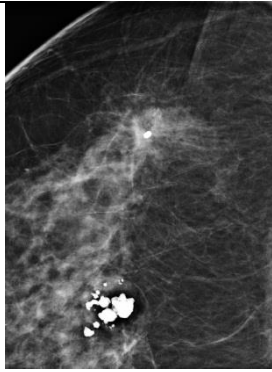
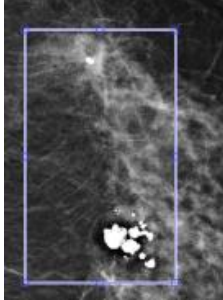
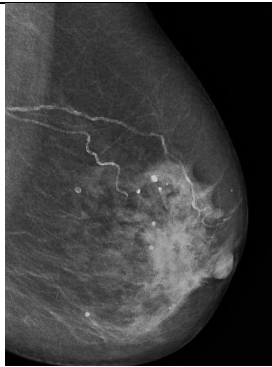
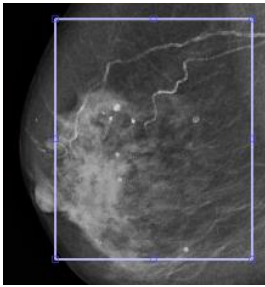
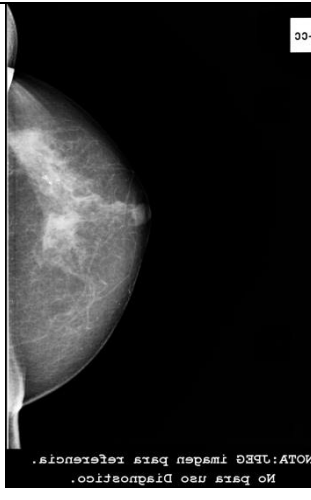
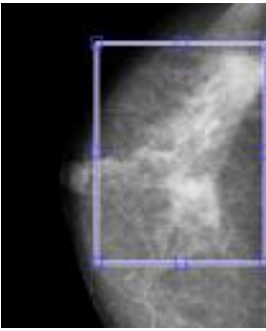
Se elige la red entrenada con 1% de error máximo y con 20 neuronas en su capa intermedia, para luego probarla y validarla.

3.2.8. Prueba de la red neuronal como elemento clasificador de microcalcificaciones



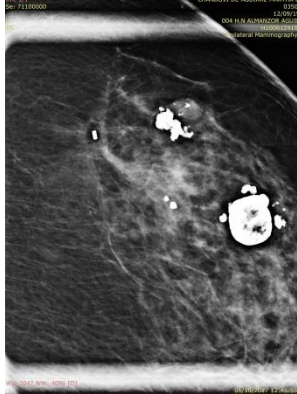
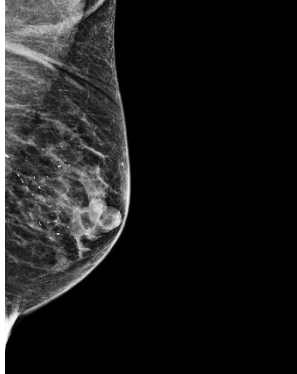
Para entrenar con Neuroph Studio, se utilizan los vectores de características o descriptores calculados en Matlab, pero se convierten a formato CSV (valores separados por coma) con la función csvwrite, creándose el archivo llamado ‘ArchivoCSVEntren’ en Matlab.



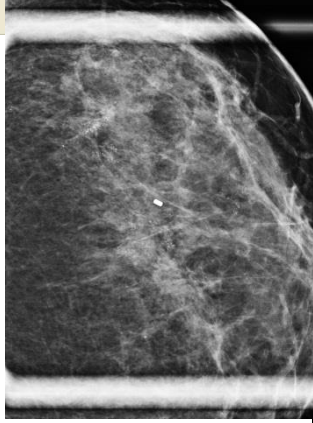

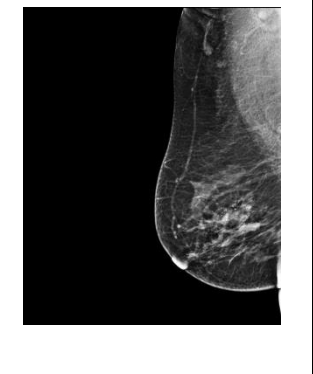
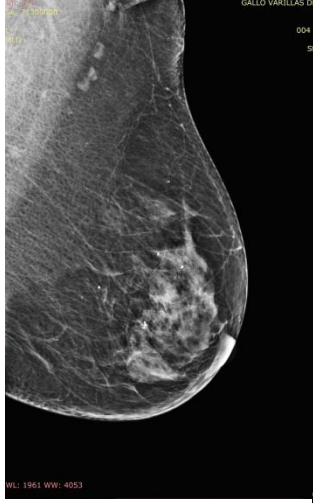
Tabla 13. Dataset etiquetado de imágenes digitales mamográficas construido para el test del clasificador neuronal.

<p>1 Imagen-prueba (benigna)1</p>			<p>Benigna (0)</p>	<p>BIRADS 2 Calcificaciones gruesas y agrupada</p>
<p>2 Imagen-prueba (benigna)2</p>			<p>Benigna (0)</p>	<p>BIRADS2 Calcificaciones vasculares y redondas</p>
<p>3 Imagen-prueba (benigna)3</p>			<p>Benigna (0)</p>	<p>BIRADS 2 Calcificaciones gruesas agrupadas</p>



<p>4</p> <p>Imagen-prueba (benigna)4</p>		<p>Benigna (0)</p>	<p>BIRADS 2</p> <p>Calcificaciones agrupadas</p>
<p>5</p> <p>Imagen-prueba (benigna)5</p>		<p>Benigna (0)</p>	<p>BIRADS 3</p> <p>Calcificaciones gruesas agrupadas</p>
<p>6</p> <p>Imagen-prueba (benigna)6</p>		<p>Benigna (0)</p>	<p>BIRADS 2</p> <p>Calcificaciones pop corn</p>
<p>7</p> <p>Imagen-prueba (sospechosa)1</p>		<p>Sospecho sa (1)</p>	<p>BIRADS 4</p> <p>Microcalcificacions lineales</p>



<p>8</p> <p>Imagen-prueba (sospechosa)2</p>		<p>Sospecho sa (1)</p>	<p>BIRADS 4</p> <p>Microcalcificacions pleomorficas finas</p>
<p>9</p> <p>Imagen-prueba (sospechosa)3</p>		<p>Sospecho sa (1)</p>	<p>BIRADS 4</p> <p>Microcalcificacions lineales y pleomorficas</p>
<p>11</p> <p>Imagen-prueba (sospechosa)5</p>		<p>Sospecho sa (1)</p>	<p>BIRADS 4</p> <p>Microcalcificaciones Pleomorficas</p>
<p>12</p> <p>Imagen-prueba (sospechosa)6</p>		<p>Sospecho sa (1)</p>	<p>BIRADS 4</p> <p>Microcalcificaciones lineales finas algunas groseras agrupadas</p>

Dataset para prueba de la red neuronal con lo que logra aprender las características de las microcalcificaciones



Salida de la red neuronal para las imagenes de prueba benignas

Input:imagen1;Output: 0,1183; Desired output: 0; Error: 0,1183
Input:imagen2;Output: 0,1183; Desired output: 0; Error: 0,1183
Input:imagen3;Output: 0,0975; Desired output: 0; Error: 0,0975
Input:imagen4;Output: 0,0524; Desired output: 0; Error: 0,0522
Input:imagen5;Output: 0,0552; Desired output: 0; Error: 0,0416
Input:imagen6;Output: 0,085; Desired output: 0; Error: 0,085

Salida de la red neuronal par alas imagenes de prueba sospechosas

Input:imagen1;Output: 0,778; Desired output: 1; Error: -0,222
Input:imagen2;Output: 0,1769; Desired output: 1; Error: -0,8231
Input:imagen3;Output: 0,9972; Desired output: 1; Error: -0,0028
Input:imagen4;Output: 0,9074; Desired output: 1; Error: -0,0926
Input:imagen5;Output: 0,9786; Desired output: 1; Error: -0,0214
Input:imagen6;Output: 0,9972; Desired output: 1; Error: -0,0028

IV. CONCLUSIONES Y RECOMENDACIONES

4.1. Conclusiones

1. Se logro implementar la data set con 9 imágenes benignas y 9 sospechosas para motivos de entrenamiento asi como 6 imágenes benignas y 6 sospechosas para el test de la red neuronal experimentada en el framework de java Neuroph Studio. Para el tratamiento digital y cálculos computacionales se utilizó el software orientado a matrices Matlab. También durante la investigación académica se tuvo el apoyo de médicos radiólogos quienes verificaron y validaron las patologías presentes en las imágenes seleccionadas.
2. En la evaluacion de la mejor tecnica de reduccion de ruido con diferentes filtros aplicados a la imagen original con respecto a la imagen con microcalcificaciones se elige al filtro no lineal de la mediana como el de mejor respuesta(45.5 db).Se aprecia que este filtro elimina el ruido de alta frecuencia sin eliminar características significativas de la imagen.
3. En la evaluacion del realce de contraste(CII) con diferentes metodos aplicados a la imagen original con respecto a la imagen con microcalcificaciones el de mejor respuesta es la correccion gamma >1 ,mostrando un indice de mejora de contraste de 1.58. Otra tecnica que se utiliza es la ecualizacion del histograma adaptativo con contraste limitado.
4. Entre la etapa de preprocesamiento y segmentación he utilizado técnicas y algoritmos basados en morfología matemática, la transformada Top Hat por apertura, ya que permite seleccionando adecuadamente el elemento estructurante, retener exclusivamente los objetos de un tamaño mayor que el determinado por el radio de dicho elemento. En esta investigación se utilizó un elemento estructural no lineal ‘ball-shaped’, de forma elipsoide, de radio 8 y altura 35, obteniendo finalmente con doble transformación una subsegmentacion. Las microcalcificaciones quedan mucho mejor separadas del resto de objetos mediante esta transformada.
5. Para aminorar el gasto computacional, ayuda en gran parte restringir el área de interés, lo que en mi caso realizo un recorte, reduciendo el fondo de la imagen y el rotulo que indica el tipo de proyección en que fue realizada la mamografía. Así también se determinó que con las funciones o librerías propias de Matlab el costo computacional es mucho menor, más eficiente y rápido.



6. Las microcalcificaciones son muy pequeñas. Los tamaños de microcalcificaciones están en el rango de 0.1-1 mm, y el promedio es de aproximadamente 0.3 mm. según experimentación. Algunos aislados más pequeños de 0.1 mm no se puede distinguir en la película mamográfica del ruido de alta frecuencia y aún más en imágenes mamográficas densas.

7. En la segmentación el método de la umbralización local tiene mayor estabilidad, pero es más dependiente de la selección de parámetros, como por ejemplo elegir el valor umbral del histograma, para poder observar las microcalcificaciones. En este trabajo de investigación se utilizó el método de Otsu (Otsu, 1979), pues esta técnica de umbralización automática selecciona el umbral óptimo maximizando la varianza entre clases mediante una búsqueda avanzada, obteniéndose el umbral adecuado y automático para extraer el objeto microcalcificaciones del resto de la imagen.

8. En algunos tejidos densos, y / o engrosamiento de la piel, especialmente en los senos de mujeres jóvenes, áreas sospechosas son casi invisibles. Los tejidos densos especialmente en las mujeres más jóvenes pueden malinterpretarse fácilmente como microcalcificaciones, y una alta tasa de falsos positivos (FP), que es el principal problema con la mayoría de los algoritmos, podrían ser encontrados. También se deduce que la mayoría de los FP se debe a un error de emulsión de película, artefactos de digitalización, o estructuras anatómicas tales como hebras fibrosas, bordes de la mama o lóbulos hipertrofiados que se parecen a microcalcificaciones.

Por lo que se podría deducir que procesar mama densa dificulta el diagnóstico mamográfico de un cáncer inicial de mama.

9. Considerando el histograma de una mamografía como una distribución estadística, la mamografía con un histograma uniforme tendrá más información. Podemos obtener la máxima entropía si igualamos el histograma lo más uniforme posible, y esto da como resultado el mejoramiento de las mamografías. Con el fin de igualar el histograma independientemente en regiones segmentarias, se utiliza el método de ecualización adaptativa del histograma. Sin embargo, algunos tejidos normales y el ruido serán también realzados. Este tipo de ecualización distribuye en todo el rango de valores de gris las zonas de la imagen que tengan fondo y formas cuyas intensidades estén representadas en rangos cercanos y por tanto con bajo contraste, lo que ayuda a encontrar microcalcificaciones que aparentemente están escondidas.



10. Se experimentó utilizando la imagen del Phantom como patrón para encontrar el área mínima posible de las microcalcificaciones y evitar que objetos ruidosos de áreas menores sean confundidas y tomadas en cuenta la identificación y detección final, lográndose determinar que se detectan microcalcificaciones de aproximadamente 0.3 mm.

11. Cuando se recorta la imagen para obtener la región de interés se recomienda no elegir contornos de mama ya que el sistema lo puede confundir como contornos parecidos a microcalcificaciones.

12. Finalmente se logra un sistema con una sensibilidad del 83%, una especificidad del 100%, una exactitud del 91%, una precisión del 100% y una tasa de error del 8.3% con el framework de java Neuroph Studio Studio, utilizado para el entrenamiento y test de la red neuronal de esta investigación. También se obtiene la curva ROC y se calcula el área bajo de curva en 0.91.

4.2. Recomendaciones

1.-En la etapa de adquisición como mayormente se utiliza para digitalizar convertidores análogo-digitales de 8 bits se recomienda usar mayores, para obtener imágenes de mayor resolución. Se sabe que para digitalizar se procede a muestrear la señal analógica que es continua, a lo largo de los ejes x e y de la placa, de modo que a cada pixel de la matriz resultante, la señal analógica detectada se convierte en un valor numérico entero, que en un convertidor de 8 bits resultaría $256=2^8$ valores (del 0 al 255) en cambio por ejemplo en uno de 12 bits resultaría $4096=2^{12}$ y puede ir desde cero al 4095 (de menor a mayor atenuación).

2.-Emplear mamografías de alta resolución. Aunque se sugiere que una matriz de píxeles de al menos 2048×2560 sea la resolución espacial mínima requerida para la mamografía digital, la resolución espacial y el rango dinámico (niveles de gris por píxel) requeridos para representar adecuadamente microcalcificaciones en un mamografía digitalizada aún es una pregunta abierta. Requiere alta resolución para ver los detalles y el amplio rango dinámico para capturar en estructuras de una sola imagen y baja sensibilidad a la luz para acortar la exposición y reducir la dosis de rayos X.).



3.-Como lo logrado en este trabajo lo considero como las primeras investigaciones locales, lo situo como un software en desarrollo, entonces recomiendo utilizar el método en espiral para continuar esta investigación experimentando y comparando otros métodos para lograr optimización y aún más orientarlo a la detección de nódulos o masas tumorales que similarmente presentan características de forma y localización para detectar su grado de malignidad.

4.-El vector de características que sirvió para entrenar a la red neuronal contiene tanto los descriptores de forma y localización, así como de intensidad .Se recomienda considerar los descriptores de textura , pues cuanto más información reciba la red neuronal mejor clasificara a los objetos en evaluación. Tambien recomiendo entrenar la red neuronal con una mayor cantidad de imágenes para obtener un mejor aprendizaje.

REFERENCIAS

- Aguilera, C. G. (No indica). *Introduccion al Analisis de Imagen*. Salamanca-España: No indica.
- Marcos, Ana Gonzales...[et al.]. (2006). *Tecnicas y Algoritmos basicos de vision artificial*. La Rioja-España: S/E.
- Avelino, L. J. (2015). *Sistemas de ayuda al diagnostico y reconocimiento de microcalcificaciones en mamografia mediante descriptores de escala y redes jerarquicas*. Madrid-España.
- Breastcancer.org. (Ultima modificacion 2018). ¿Que es el cancer de mama? *Breastcancer.org*.
- Cajusol, J. &. (2019). Universidad Nacional Pedro Ruiz Gallo, Lambayeque, Lambayeque.
- Carlos, G. (2014). *Segmentacion de imagenes medicas mediante algoritmos de colonia de hormigas*. Pontifica Universidad Catolica del Peru, Escuela de posgrado.
- Cesar, S. d. (2014). *Propuesta de tecnica para la estimacion de densidad mamaria en mamografias digitales utilizando tecnicas de segmentacion y estimadores globales*. Pontifica Universidad Catolica del Peru, Facultad de Ciencias e Ingenieria.
- Diaz, S. O. (2014). *Clasificacion de imagenes de mamografias segun el tipo de tejido predominante usando redes neuronales artificiales*.
- Fernado Lage, Z. C. (2007). *Procesamiento digital de imágenes radiográficas de baja calidad con onditas: Caso de diagnostico en pequeños mamiferos*. Buenos Aires: C1063ACV.
- Jimenez, J. M. (2008). *Introducción al tratamiento Digital y Clustering de Imagenes. Procesado de Imagen*.
- Juan, A. (2014). *Sistema de deteccionde cancer de mama en mujeres, mediante el uso de redes neuronales*. Universidad del Altiplano Puno, Puno.
- Manrique, D. (1999). *Detección Automática de Regiones de Interés en Mamografías Digitalizadas para el Diagnóstico Asistido por Ordenador-Análisis del Histograma de la imagen de Entrada. Informatica y Salud*.
- Manzano Lizcano, J. A. (2015). *Sistema de ayuda al diagnostico y reconocimiento de microcalcificaciones en mamaografia mediante descriptores de escala y redes jerarquicas*.



Perez, M. G. (2015). *Deteccion automatica de lesiones en mamografias usando tecnicas de analisis de imagenes*. Ambato-Ecuador.

Platero Dueñas, C. (2008). *Apuntes de Vision Artificial*. Madrid-España: S/E.

Roxana, L. (2016). *Un enfoque hibrido para la clasificacion de imagenes de resonancia magnetica del cerebro*. UNSA, Vicerectorado de investigacion, Arequipa.

Santamaria, J. C. (2014). *Construccion de una base de datos de imagenes de mamografia para la identificacion de microcalcificaciones*. Universidad Tecnologica de Pereira-Colombia, Pereira.



ANEXOS

Código para hallar el Valor Promedio de los niveles de gris o brillo de una imagen

```
function PROM=PromValorGris(imag)
imag=double(imag);
b=0;
for i=1:size(imag,1)
for j=1:size(imag,2)
    b=b+double(imag(i,j));
end
end
PROM=b/(size(imag,1)*size(imag,2));% Brillo o valor medio de los niveles de grises
de la imagen(B={(1/MxN)[(SUMATORIA DOBLE desde 1 hasta M, desde 1 hasta
N)de
%(f(x,y))}]
end
```

Código para la hallar la Desviación Estándar o contraste de una imagen

```
function C=DesviacionStd(ima)%Desviacion Standar, que es una medida del grado de
dispersión o la variabilidad de los datos con respecto al valor promedio
ima=double(ima);
B=PromValorGris(ima);
cont=0;
for i=1:size(ima,1)
for j=1:size(ima,2)
    cont=cont+(abs(((ima(i,j)-B))))).^2;
end
end
C=cont/(size(ima,1)*size(ima,2)); %Contraste={(1/MxN)[(SUMATORIA DOBLE
desde 1 hasta M, desde 1 hasta N)de
%(f(x,y)-B)^2]}^0.5
```



$C = \sqrt{C}$; %El contraste indica la medida de dispersión de los niveles de gris en la imagen.

end

Código para la función Error Cuadrático Medio(MSE).

function MSE=ErrorCuadMedio(orig,proc)%Mide la diferencia entre la imagen original y la imagen postprocesada

%MSE={ $(1/M \times N)[(\text{SUMATORIA DOBLE desde } 1 \text{ hasta } M, \text{ desde } 1 \text{ hasta } N)de(f(x,y) - f'(x,y))^2]$ }

%Donde: $(f(x,y) - f'(x,y))^2 = f(x,y)^2 - 2 * f(x,y) * f'(x,y) + f'(x,y)^2$

%MSE=M1-M2+M3

orig=double(orig);

proc=double(proc);

mean1=0;

for i=1:size(orig,1)

for j=1:size(orig,2)

 mean1=mean1+double((orig(i,j).^2));

end

end

M1=mean1/(size(orig,1)*size(orig,2));

mean2=0;

for i=1:size(orig,1)

for j=1:size(orig,2)

 mean2=mean2+double(2*(orig(i,j)*(proc(i,j))));

end

end

M2=mean2/(size(orig,1)*size(orig,2));

mean3=0;

for i=1:size(proc,1)

for j=1:size(proc,2)

 mean3=mean3+double((proc(i,j).^2));

end

end

M3=mean3/(size(proc,1)*size(proc,2));



MSE=M1-M2+M3;

End

Código para la función Oblicuidad(Desviacion Asimetrica).

function SK=Oblicuidad(ima)%Desviacion asimétrica(skewnees-oblicuidad), y que puede ser positiva: doblado a la izq-simetrica-negativa:doblado ala derecha)

ima=double(ima);

B=PromValorGris (ima);

D=DesviacionStd(ima);

cont=0;

for i=1:size(ima,1)

for j=1:size(ima,2)

cont=cont+double(((ima(i,j)-B)/D).^3);

end

end

SK1=cont/(size(ima,1)*size(ima,2)); %SK1={ (1/MxN)[(SUMATORIA DOBLE desde 1 hasta M, desde 1 hasta N)de(f(x,y)-B)^3]}

SK=(SK1)/(SK1^0.5);%OBLICUIDAD DE LOS DATOS CON RESPECTO A LA MEDIA

End

DECLARACION JURADA

Yo, ALAIN RICHARD TORRES MIÑANO con DNI No 18003533

y con domicilio para los efectos de la presente en CALLE TUDAM: 319 Urb.
MIRAFLORES-I-ETAPA - CHICLAYO

DECLARO BAJO JURAMENTO

Siendo Medico, en la especialidad de Radiología, que las imágenes mamográficas que me presento el tesista Raúl Quesquen Liza, han sido verificadas y validadas por mi persona para fines de investigación académica.


MAS SALUD PARA LOS PERUANOS
HOSPITAL NAYLAMP
SERVICIO DE RADIOLOGÍA

Alain Torres Miñano
C.M.P. 30785

CMP 30785

Chiclayo, 4 de septiembre del 2019




DECLARACION JURADA

Yo, GRACIELA CESPEDES GIL ARROYO con DNI No 44398225
y con domicilio para los efectos de la presente en LOS FAIGUES N° 109 STA VICTORIA

DECLARO BAJO JURAMENTO

Siendo Medico, en la especialidad de Radiología, que las imágenes mamográficas que me presento el tesista Raúl Quesquen Liza, han sido verificadas y validadas por mi persona para fines de investigación académica.



Graciela Cespedes Gil Arroyo
MEDICO RADIOLOGA

CMP. 64254 - RNE. 34254

CMP 64254

Chiclayo, 4 de septiembre del 2019

