Diseño e implementación de un algoritmo de segmentación del seno para mamografías digitalizadas

Gabriela Galvis Gómez

Trabajo de Grado para optar al título de Ingeniero Electrónico

Director

Said Pertuz, Ph.D

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones

Bucaramanga

2023

Agradecimientos

En primer lugar, gracias a Dios por guiarme y darme la fortaleza para lograr cumplir uno de mis anhelos más grandes. Muchas gracias a mi madre, Martha Liliana Gómez Rincón, quien desde un inicio me ha apoyado incondicionalmente a lo largo de este proceso, el cual no hubiese sido posible sin ella. Gracias a mi novio, Carlos Daniel Peñaloza Torres, por estar a mi lado en los momentos difíciles, por siempre creer en mí y brindarme todo su amor y comprensión. Gracias a mi familia y amigos por acompañarme en este proceso e impulsarme a esforzarme cada vez más hasta cumplir mis metas. Gracias al profesor Jeyson Castillo por todos sus consejos y el tiempo dedicado a aclarar mis dudas. Gracias a mi director Said Pertuz, por orientarme durante el desarrollo de este trabajo. Por último, gracias a la Universidad Industrial de Santander, por la oportunidad de estudiar en esta gran alma mater y brindarme los recursos necesarios para poder culminar este proyecto.

Contenido

Introducción **9**

1. Objetivos **12**

1.1. Objetivo General 12

1.2. Objetivos Específicos 12

2. Revisión de literatura **13**

2.1. Preprocesamiento de imágenes 13

2.2. Segmentación del músculo pectoral 14

2.3. Posprocesamiento de imágenes 16

3. Materiales y métodos **18**

3.1. Conjunto de datos 18

3.2. Preprocesamiento de imágenes 20

3.3. Segmentación del músculo pectoral 21

3.4. Posprocesamiento de imágenes 23

3.5. Medidas de desempeño 26

4. Experimentos y resultados **27**

4.1. Estudio de ablación 27

4.2. Resultados de desempeño 30

5. Discusión y conclusión **32**

Referencias bibliográficas **34**

Lista de Figuras

Figura 1. Diagrama de la metodología 18

Figura 2. Ejemplos de mamografías de la base de datos Mini-MIAS 19

Figura 3. Preprocesamiento de la imagen mamográfica 21

Figura 4. Segmentación del músculo pectoral utilizando crecimiento de regiones 23

Figura 5. Posprocesamiento del músculo pectoral usando polinomios de grado 1 y 2 25

Figura 6. Imagen con el músculo pectoral segmentado usando un polinomio de grado 1 25

Figura 7. Proceso de extracción del músculo pectoral 31

Lista de Tablas

Tabla 1. Resumen de investigaciones relevantes 17

Tabla 2. Medidas de rendimiento variando el umbral y el píxel semilla 29

Tabla 3. Medidas de rendimiento variando el grado del polinomio 30

Resumen

Título: Diseño e implementación de un algoritmo de segmentación del seno para mamografías digitalizadas [*]

Autor: Gabriela Galvis Gómez [**]

Palabras Clave: algoritmo, mamografía, músculo pectoral, segmentación.

Descripción: En la actualidad, una de las herramientas que se utilizan para la detección temprana del cáncer de mama es la mamografía, la cual se divide en dos tipos: *digital* y *digitalizada*. La principal diferencia entre estas consiste en el formato de adquisición que poseen, lo que con lleva a que ambos tipos de imágenes posean características diferentes, tales como el rango dinámico, ruido estructural, entre otras. Las mamografías suelen contener el músculo pectoral, el cual es necesario eliminar debido a que posee una intensidad similar a la del tejido mamario. Para esto se utilizan los algoritmos de segmentación, los cuales se encargan de separar el tejido mamario y la pared pectoral. Debido a las diferencias entre los tipos de mamografías, estos algoritmos trabajan adecuadamente en imágenes *digitales*, pero presentan problemas al momento de utilizar imágenes *digitalizadas*. Por consiguiente, para llevar a cabo el análisis computarizado de este tipo de imágenes es necesario contar con algoritmos que sean afines con mamografías digitalizadas. Por esta razón, este trabajo se enfocó en el diseño e implementación de un algoritmo que permitiera segmentar el músculo pectoral en imágenes digitalizadas de la base de datos mini-MIAS. Para esto, se llevó a cabo un preprocesamiento de las imágenes con el fin de mejorar la calidad y eliminar objetos indeseados. Después se utilizó la técnica de segmentación por crecimiento de regiones (RG) para segmentar el músculo pectoral de la imagen. Posteriormente, se utilizaron técnicas de posprocesamiento de imágenes para mejorar los resultados obtenidos y finalmente, se realizó la evaluación del algoritmo utilizando como medidas de rendimiento el *accuracy* y el coeficiente de similitud de Dice. El algoritmo desarrollado logró un rendimiento del 89.16% en la media del coeficiente de similitud de Dice y un 88.04% en la exactitud, cada uno con una desviación estándar de aproximadamente el 6%. Los resultados obtenidos demuestran la eficiencia del algoritmo para eliminar el músculo pectoral en la mayoria de las imágenes.

---

[*] Trabajo de Grado

[**] Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingenierías Eléctrica, Electrónica y telecomunicaciones. Director: Said Pertuz, PhD.

Abstract

Title: Design and implementation of a breast segmentation algorithm for digitized mammograms [*]

Author: Gabriela Galvis Gómez [**]

Keywords: algorithm, mammography, pectoral muscle, segmentation.

Description: Currently, one of the tools used for early detection of breast cancer is mammography, which is divided into two types: *digital* and *digitized*. The main difference between these consists in the acquisition format, which means that both types of images have different characteristics, such as the dynamic range, structural noise, among others. Mammograms often contain the pectoral muscle, which needs to be removed because it has a similar intensity to that of breast tissue. For this, segmentation algorithms are used, which are responsible for separating the breast tissue and the pectoral wall. Due to the differences in characteristics between the types of mammograms, these algorithms work adequately in *digital* images, but present problems when use *digitized* images. Therefore, to carry out the computerized analysis of this type of images it is necessary to have algorithms that are compatible with digitized mammography. For this reason, this work focused on the design and implementation of an algorithm that would allow the segmentation of the pectoral muscle in digitized images from the mini-MIAS database. For this, a pre-processing of the images was carried out in order to improve the quality and eliminate unwanted objects. The region growing (RG) technique was then used to segment the pectoral muscle in the image. Subsequently, image post-processing techniques were used to improve the results obtained and finally, the evaluation of the algorithm was carried out using the Dice's coefficient similarity and the accuracy as a performance measure. The developed algorithm achieved a performance of 89.16 % on the mean of the Dice's coefficient similarity and 88.04 % in the mean of the accuracy, each with a standard deviation of approximately 6 %. The results obtained demonstrate the efficiency of the algorithm to eliminate the pectoral muscle in most of the images.

---

[*] Bachelor's Thesis

[**] Faculty of Physical-Mechanical Engineering. School of Electrical, Electronic and Telecommunications Engineering. Director: Said Pertuz, PhD.

Introducción

El cáncer de mama es la segunda causa de mortalidad entre las mujeres en todo el mundo, después del cáncer de pulmón (Pertuz et al., 2019). Según la Organización Mundial de la Salud, aproximadamente una de cada ocho mujeres se ve afectada actualmente por cáncer de mama durante su vida (Rahmatika et al., 2019). Debido a esto, es de vital importancia lograr su temprano descubrimiento, con el fin de reducir la tasa de mortalidad y aumentar las posibilidades de supervivencia. En la actualidad, se utilizan muchas técnicas para la detección temprana del cáncer de mama, entre ellas la mamografía se ha convertido en una de las más confiables. Esta consiste en la toma de imágenes por medio de una baja dosis de rayos X que permite la visualización de la estructura interna del seno (Pertuz et al., 2019), permitiendo así distinguir anomalías en la mama. Existen dos tipos de mamografía: digital y digitalizada. Las imágenes digitales se almacenan directamente en formato digital desde el momento de su adquisición. Por el contrario, las imágenes digitalizadas se obtienen directamente sobre un papel película debido al tipo de detectores que se usan en la adquisición (Chevalier y Torres, 2010), por lo cual deben ser posteriormente digitalizadas con el fin de ser visualizadas y procesadas en equipos de cómputo.

Las diferencias en la adquisición de las imágenes mamográficas conlleva a que estas posean distintas propiedades como lo son la resolución, el contraste, ruido estructural, el rango dinámico, entre otras (Chevalier y Torres, 2010). Principalmente, las mamografías digitalizadas poseen un rango dinámico estrecho, lo cual afecta la detección de variaciones sutiles en densidad y composición de los tejidos, a causa de las atenuaciones que se presentan en la imagen (Chevalier y Torres,

2010).

Si bien los sistemas mamográficos modernos corresponden a sistemas digitales, en Colombia aún es recurrente el uso de la imagen digitalizada. Entre las ventajas de estas imágenes se encuentran su alta resolución espacial y alto contraste (Chevalier y Torres, 2010). Estas mamografías digitalizadas son examinadas por un radiólogo experto que identificará cualquier anomalía en los senos de la paciente. Sin embargo, estos radiólogos tienen muchas imágenes que inspeccionar, lo cual suele ser una tarea ardua que puede llevar a que exista un diagnóstico erróneo debido a la fatiga (Moghbel et al., 2020). Con el fin de brindar una herramienta que sea de ayuda para el radiólogo, se ha propuesto el uso del diagnóstico asistido por computadora (CAD), el cual ha mostrado tener un buen potencial en la detección de anomalías y una mejora en el diagnóstico del cáncer de mama (Africano et al., 2020). Un paso necesario para la utilización de estos sistemas CAD en el análisis de mamografías digitalizadas es la identificación correcta de la región mamaria (Africano et al., 2020). Por consiguiente, es imprescindible identificar el músculo pectoral en la imagen para así excluirlo y poder realizar el análisis computarizado. Para lograr esto se utilizan algoritmos de segmentación, los cuales tienen como fin detectar el músculo pectoral en la imagen para posteriormente eliminarlo. Los algoritmos del estado del arte están desarrollados para mamografías digitales, por lo que presentan problemas al ser usados con mamografías digitalizadas, debido a las diferencias de características entre ambos tipos de imágenes. Esto produce que no se pueda segmentar el músculo pectoral de la imagen, dificultando realizar análisis computarizado a imágenes digitalizadas. Por lo tanto, es fundamental el desarrollo de algoritmos de segmentación compatibles con este tipo de imágenes, con la finalidad de brindar una herramienta que facilite el

análisis computarizado de estas. En la literatura se encuentran diferentes algoritmos propuestos para la segmentación del músculo pectoral en mamografías. En la sección 2 se presenta una revisión detallada del estado del arte.

Este proyecto tiene como objetivo desarrollar un algoritmo de segmentación del músculo pectoral que sea compatible con imágenes digitalizadas, utilizando técnicas de procesamiento de imágenes. El desarrollo y evaluación se llevaron a cabo con imágenes de la base de datos mini-MIAS[1], la cual contiene 322 mamografías digitalizadas de vista medio lateral oblicua (MLO) de 161 pacientes.

---

[1] Mammographic Image Analysis Society (MIAS).

1. Objetivos

1.1. Objetivo General

Diseñar e implementar un algoritmo que permita segmentar la pared pectoral en mamografías digitalizadas.

1.2. Objetivos Específicos

1. Acondicionar la base de datos Mini-MIAS para su análisis en las etapas posteriores del proyecto.

2. Diseñar e implementar un algoritmo para la segmentación de la pared pectoral en imágenes digitalizadas utilizando técnicas de procesamiento de imágenes.

3. Evaluar el rendimiento del algoritmo para segmentar la pared pectoral en imágenes digitalizadas y realizar un análisis de los resultados obtenidos.

2. Revisión de literatura

La segmentación del músculo pectoral es considerada una tarea compleja debido a que su forma y tamaño varían de una mamografía a otra, esto hace que carezca de regularidad, además de poseer cambios en la textura y valores de intensidad similares al tejido mamario, en especial en las mamas que presentan tejido denso, lo cual dificulta encontrar el límite pectoral. Partiendo de esto, se realizó una revisión bibliográfica en el área de segmentación del músculo pectoral con el fin de sintetizar en esta sección las etapas más comunes que se llevan a cabo en la literatura para lograr este proceso. Estas etapas son: preprocesamiento de imágenes, segmentación del músculo pectoral y posprocesamiento de imágenes.

2.1. Preprocesamiento de imágenes

Investigaciones previas han demostrado que el preprocesamiento es un paso necesario para mejorar la calidad de las imágenes mediante técnicas que permitan realzar los detalles deseados de la imagen y realizar la eliminación de información que no sea de interés, facilitando el posterior análisis de la imagen. Entre los métodos más comunes de la etapa de preprocesamiento se encuentran: el filtrado, que se utiliza para suavizar la imagen mediante la disminución de los efectos del ruido. Entre los tipos de filtros usados está el filtro de mediana, que suele ser muy utilizado para eliminar el ruido de sal y pimienta (Rahmatika et al., 2019), el *closing* o filtro de cierre, es un filtro morfológico que permite rellenar huecos en la imagen sin alterar considerablemente el área de los objetos y el *opening* o filtro de apertura, que es un filtro morfológico que tiene como fin de eliminar los objetos más pequeños que el elemento estructurante, manteniendo el área de los demás objetos.

Otra técnica de preprocesamiento es la binarización, que se utiliza para reducir la imagen a una escala de grises donde los píxeles tienen valores booleanos. La ecualización del histograma es un método de preprocesamiento que se utiliza para mejorar el contraste de la imagen, su objetivo es hacer que la distribución de las intensidades de los píxeles sea uniforme. El recorte de márgenes se utiliza para eliminar regiones antes de la mejora de la imagen, evitando aumentar el ruido. La apertura de área se encarga de eliminar todos los objetos dentro de la imagen que tengan un área menor al área del objeto de interés. La rotación se usa para orientar todas las imágenes en una misma posición. El método del canal oscuro previo (DCP) desempaña la imagen aumentando los valores de intensidad de las áreas poco iluminadas y por último, la normalización para ajustar los valores de intensidad de una imagen con el fin de mejorar el contraste o limitar los niveles de gris a un rango determinado.

2.2. Segmentación del músculo pectoral

Al realizar una investigación sobre las técnicas empleadas para la segmentación del músculo pectoral en mamografías, se seleccionaron los enfoques más relevantes basados en su alto desempeño. Las técnicas usadas en la literatura las podemos agrupar en 6 categorías, las cuales estan basadas en: intensidad, detección de líneas, estadística, transformada de Wavelet, contorno activo y aprendizaje profundo; estas se describen a continuación. Los enfoques basados en la intensidad, dependen de las diferencias de intensidad entre el músculo pectoral y el tejido mamario. Estas técnicas presentan algunas dificultades debido a que los valores de intensidad del músculo pectoral y del tejido mamario suelen ser muy similares, lo que da como resultado complicaciones al momento de segmentar las dos regiones (Ganesan et al., 2013). Una de las ventajas de esta técnica es su

fácil implementación y potencia. Estos métodos funcionan bajo la suposición de que el músculo pectoral posee un valor de intensidad mayor que el valor de intensidad del resto de la imagen.

Los enfoques basados en la detección de líneas trabajan bajo el supuesto de que el límite entre el músculo pectoral y el tejido mamario es una línea recta (Ganesan et al., 2013).

Los enfoques basados en la estadística estudian las estructuras que componen la mama en función de algunas características como lo son la intensidad, textura, forma, entre otras. Teniendo estas características se puede crear un modelo estadístico que permita clasificar los píxeles mediante un criterio de discriminación basado en la información obtenida de la imagen (Ganesan et al., 2013).

Los enfoques basados en la transformada de Wavelet han sido utilizados en gran medida para la extracción de características de una imagen debido a su capacidad para obtener información sobre la frecuencia espacial. Para esto se hace uso de la descomposición de imágenes, la cual se puede realizar en distintos niveles dependiendo del tamaño del objeto de interés (Ganesan et al., 2013).

Los enfoques basados en el contorno activo consisten en una curva elástica que se coloca sobre una imagen y posteriormente esta curva comienza a deformarse con el objetivo de limitar las regiones de interés de la imagen (Ganesan et al., 2013).

Finalmente, los enfoques basados en aprendizaje profundo, suelen tener como base algún tipo de red neuronal convolucional (CNN), las cuales se encuentran formadas por capas de entrada y salida con varias capas ocultas en el medio que suelen ser capas convolucionales, lo que significa que convolucionan con la aplicación de algún tipo de función matemática (Zhou et al., 2022). En el

análisis de imágenes se utilizan las capas convolucionales para aprender sesgos con el fin de asignarle diferentes grados de importancia a las regiones de una imagen para así poder diferenciarlas (Zhou et al., 2022).

La tabla 1 presenta un resumen de las investigaciones previas sobre segmentación del músculo pectoral en mamografías. Esta selección se llevó a cabo teniendo en cuenta el desempeño de los algoritmos, la base de datos que utilizaron y las etapas que se realizaron durante el proceso.

2.3. Posprocesamiento de imágenes

El posprocesamiento de las imágenes es un paso importante que permite refinar los resultados que se obtienen luego de segmentar el músculo pectoral. Esto permite obtener una mejora en los resultados finales del proceso de segmentación. Para este proceso se suelen utilizar los mismos métodos de mejora de la imagen mencionados anteriormente en el preprocesamiento de imágenes. Otra técnica de posprocesamiento consiste en seleccionar cuatro puntos del músculo pectoral segmentado para construir una línea recta, con el fin de corregir los bordes ásperos del límite del músculo pectoral obtenidos como resultado del proceso de segmentación por crecimiento de regiones (Nagi et al., 2010). Otra forma de corregir los bordes ásperos consiste en ajustar un polinomio a los puntos del límite del músculo pectoral, obteniendo la curva que mejor se aproxime al conjunto de puntos (Hamissi y Merouani, 2012).

Tabla 1

Resumen de investigaciones relevantes

Referencia	Método	Base de datos	Desempeño
Métodos de intensidad			
(Elmoufidi, 2019)	Crecimiento de regiones	*mini – MIAS*[1]: 115 mamografías *DDSM*[2]: 500 mamografías	ACC: *mini – MIAS*[1]: 97.89 %, *DDSM*[2]: 98.26 %
(Naz et al., 2017)	Umbralización global y matriz de conectividad mínima	*mini – MIAS*[1]: 322 mamografías	ACC: 92.86 %
(Rahmatika et al., 2019)	k-means	*mini – MIAS*[1]: 25 mamografías	ACC: 89 %
(Africano et al., 2020)	Gradiente de área morfológica (MAG)	*INbreast*[4]: 410 mamografías	Coeficiente Dice: 86.4 %
Métodos de detección de líneas			
(Pertuz et al., 2019)	Detector de línea basado en Hough	*BCDR*[3]: 305 mamografías	AUC: 0.846
Métodos de estadística			
(Oliver et al., 2014)	Modelo probabilístico utilizando posición, intensidad y textura	*MIAS*[1]: 149 mamografías	Coeficiente Dice: 83 %
Métodos de aprendizaje profundo			
(Liu et al., 2020)	Modelo U-Net previamente entrenado	*DDSM*[2]: 2620 mamografías	Coeficiente Dice: 93.5 %
(Wang et al., 2019)	Modelo ResNet50-U-net	*DDSM*[2]: 2620 mamografías	Coeficiente Dice: 95.3 %
(Rampun et al., 2019)	Red neuronal convolucional (CNN) inspirada en la red de detección de bordes anidada holísticamente (HED).	Se evaluó en base a 1087 mamografías de cuatro conjuntos de datos diferentes: *MIAS*[1], *DDSM*[2], *BCDR*[3] e *INbreast*[4]	Coeficiente Dice: *MIAS*[1]: 97.5 %, *DDSM*[2]: 98.1 %, *BCDR*[3]: 98.8 %, *INbreast*[4]: 95.6 %

Nota.
[1]Mammographic Image Analysis Society (MIAS).
[2]Digital Database for Screening Mammography (DDSM).
[3]Breast Cancer Digital Repository (BCDR).
[4]Breast Center located in a Hospital in São João, Portugal (INbreast).

3. Materiales y métodos

En esta sección se realiza una descripción de la base de datos utilizada, los métodos usados en el preprocesamiento de las imágenes, la técnica de segmentación propuesta y el procedimiento realizado en el posprocesamiento. En la figura 1 se ilustra la metodología llevada a cabo durante el proceso.

Figura 1

Diagrama de la metodología

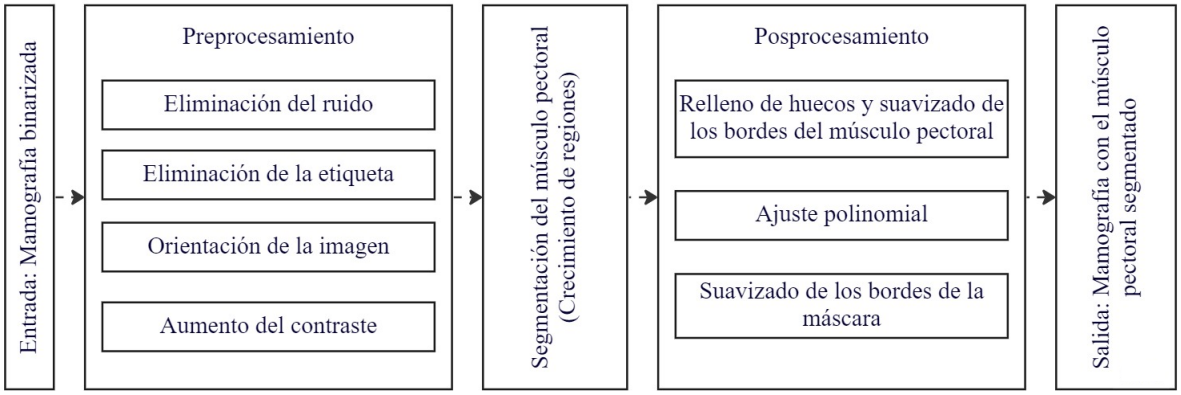

3.1. Conjunto de datos

El desarrollo y evaluación del método propuesto fue llevado a cabo con imágenes de la base de datos mini-MIAS[1]. Estas imágenes en papel película fueron proporcionadas por el Programa Nacional de Detección de Cáncer de Mama del Reino Unido y posteriormente digitalizadas con

[1] Mammographic Image Analysis Society

un intervalo de muestreo de 200 μm y cuantificación de nivel de gris de 8 bits (Saltanat et al., 2010). Esta base de datos pública contiene 322 mamografías digitalizadas de vista medio lateral oblicua (MLO) de las mamas derecha e izquierda correspondientes a 161 pacientes. Además, este conjunto de imágenes se encuentra dividido en dos categorías: 207 mamografías benignas y 115 malignas, las cuales a su vez se dividen en las categorías: grasa (106 mamografías), glandular (104 mamografías) y densa (112 mamografías), dependiendo de la intensidad de la imagen (Majeed et al., 2013). En la figura 2 se muestran dos imágenes de ejemplo de cada clase.

Figura 2

Ejemplos de mamografías de la base de datos Mini-MIAS. (a) Grasa, (b) Glandular, (c) Densa

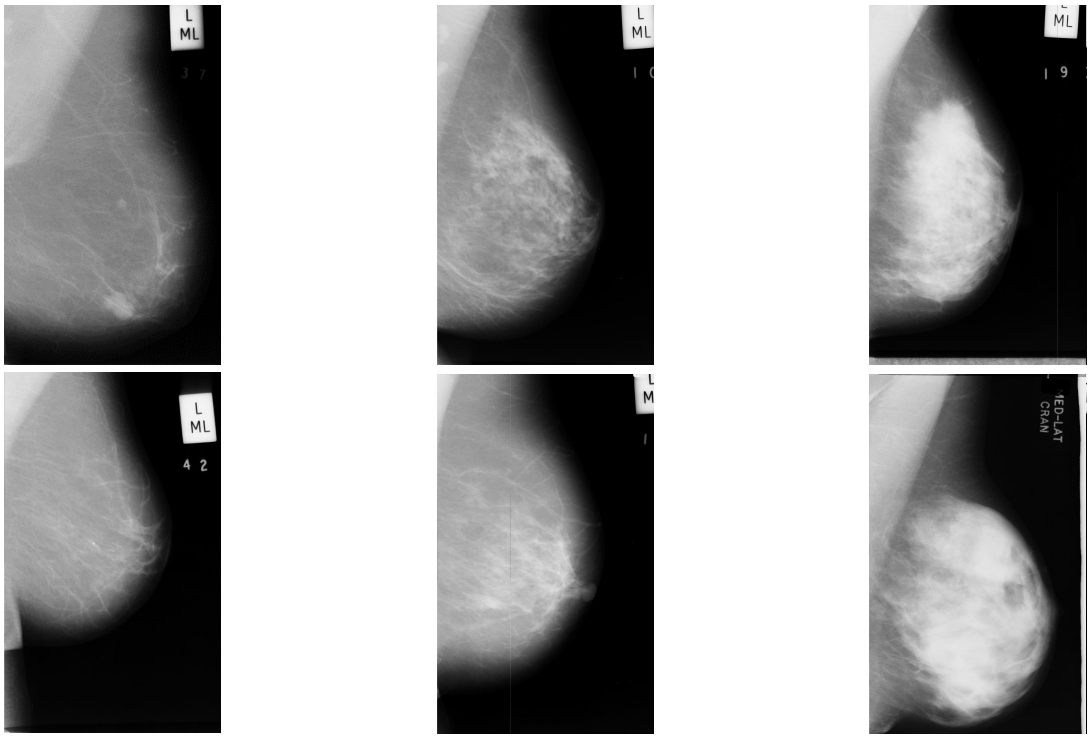

(a) (b) (c)

3.2. Preprocesamiento de imágenes

El primer paso en esta fase consistió en eliminar el ruido presente en la imagen. Para esto se utilizó el filtro de mediana usando una ventana de 3x3. El siguiente paso fue la eliminación de las etiquetas, para esto, primero se utilizó el método del canal oscuro previo (DCP) para iluminar las áreas con poca luz de la imagen con el objetivo de resaltar más la región del seno y así más adelante obtener un mejor binarizado. Después, con el fin de dividir la imagen en dos regiones, se llevó a cabo la binarización utilizando el método de Otsu. Posteriormente, se realizaron operaciones morfológicas utilizando la apertura de área con el objetivo de solo conservar en la imagen el objeto con la mayor área, es decir, la región del seno y eliminar el resto de objetos.

Realizando este proceso se pudo observar que en algunas imágenes la región del seno está unida a la etiqueta por medio de un objeto, el cual suele ser un error que se presenta en la imagen al momento de su digitalización. Esta unión produce que al realizar la binarización, estas dos partes queden unidas como un solo objeto, lo que da como resultado que al conservar solo el objeto con la mayor área, la etiqueta no sea eliminada, esto puede verse en la Figura 3(a)-(e). Debido a este problema, se agregó un paso de refinamiento utilizando el filtro morfológico de apertura con el fin de eliminar los objetos indeseados que no se pudieron eliminar en el paso anterior. Finalmente, se multiplica la máscara obtenida en el paso previo con la imagen sin ruido para obtener la imagen sin etiquetas. Otro paso del preprocesamiento fue orientar todas las mamografías hacia la derecha, con el fin de que el músculo pectoral se encontrará ubicado en el mismo lugar en todas las imágenes y por último, se realizó una ecualización del histograma con el objetivo de incrementar el contraste

de la imagen, el resultado de los pasos anteriores se muestra en la figura 3.

Figura 3

Preprocesamiento de la imagen mamográfica. (a) Imagen mamográfica original, (b) filtrado de mediana, (c) iluminación, (d) binarización, (e) apertura de área, (f) apertura morfológica, (g) sin etiquetas, (h) ecualización del histograma

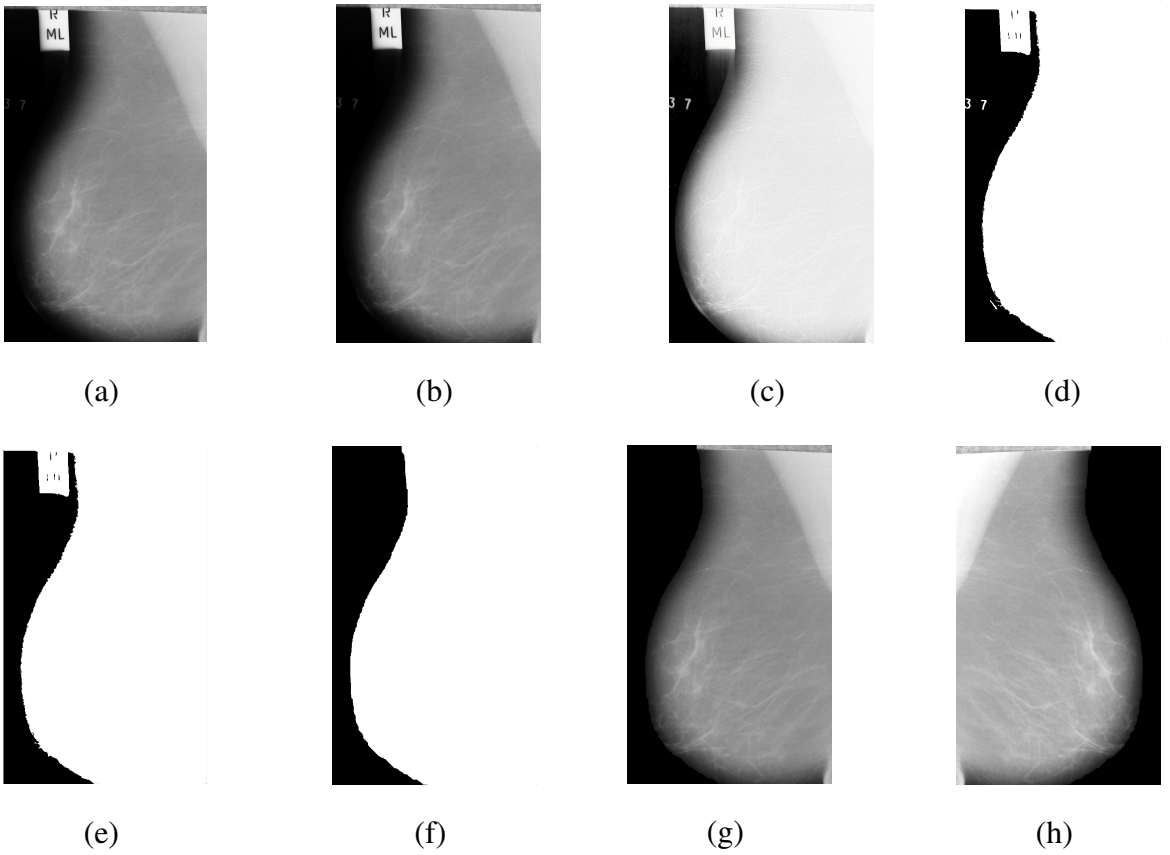

(a) (b) (c) (d)

(e) (f) (g) (h)

3.3. Segmentación del músculo pectoral

Para el proceso de segmentación del músculo pectoral se tenían como limitaciones los recursos computacionales, por lo que se optó por no trabajar con enfoques basados en aprendizaje profundo, ya que estos requieren de un mayor poder computacional. Además, se contaba con una base de datos pequeña y estos enfoques dependen de la cantidad de datos. Es por esto que se se-

leccionó para el proceso de segmentación la técnica de crecimiento de regiones (RG) debido a que es un método simple, rápido, potente y fácil de implementar. El cual no necesita de altos recursos computacionales y ha demostrado un gran desempeño al trabajar con bases de datos pequeñas.

El crecimiento de regiones es una de las técnicas más utilizadas en la segmentación de imágenes. Este es un proceso iterativo, donde se parte de una semilla, la cual representa la región a segmentar, es decir, posee las características de la región. Este píxel es comparado con sus vecinos y si se cumple con un criterio de similitud, estos píxeles son agrupados generando la región a segmentar. Este proceso se repite, haciendo que la región crezca de forma iterativa hasta que ya no se cumpla con el criterio. La selección del punto semilla y del umbral que rige el criterio de similitud son muy importantes, ya que de ellos depende el éxito del proceso de segmentación. Esta técnica se puede implementar mediante los siguientes pasos:

1. Antes de comenzar el proceso es necesario establecer un valor de intensidad para el umbral f_{th} y las coordenadas del punto semilla $p = (x, y)$.

2. Se define la región segmentada como el píxel semilla ($R = p$) y se toma como referencia el valor de intensidad de ese píxel ($ref = f(p)$).

3. Se buscan todos los píxeles vecinos de la región segmentada $p_i \in \Omega(R)$.

4. Se agregan a la región segmentada todos los píxeles vecinos que cumplan la condición $p_i \in \Omega(R) \wedge \mid f(p_i) - ref \mid < f_{th}$.

5. Se actualiza el valor de referencia como el promedio de la intensidad de todos los píxeles

en la región segmentada, incluyendo los que se incorporaron en el paso anterior $ref = media\{f(R)\}$

El algoritmo continúa repitiendo los pasos 3 al 5 hasta que ningún píxel adyacente satisfaga la condición, obteniendo como resultado la región segmentada R. En la figura 4 se muestra el resultado de aplicar este algoritmo a una imagen usando como píxel semilla $p = (32,5)$ y como umbral $f_{th} = 18$.

Figura 4

Segmentación del músculo pectoral utilizando crecimiento de regiones. (a) Imagen mamográfica original, (b) imagen mamográfica preprocesada, (c) máscara del músculo pectoral segmentado

(a) (b) (c)

3.4. Posprocesamiento de imágenes

Para mejorar la máscara pectoral obtenida en la etapa anterior, se realizó un proceso de posprocesamiento. Para ello, primero se utilizó la operación morfológica de dilatación para rellenar los huecos de la imagen y suavizar los bordes de la pared pectoral. La figura 5(b) muestra los resultados de aplicar esta operación a la imagen. Sin embargo, a pesar de realizar este procedimiento, la región segmentada aún presentaba bordes ásperos, por lo que se decidió realizar un

ajuste polinomial a los puntos que componen el límite del músculo pectoral con el fin de construir una recta o curva que se ajuste a estos datos, logrando así pulir los bordes. Para ello, se binarizó la imagen para reducirla a solo dos valores de intensidad y así poder obtener los límites del músculo pectoral. Posteriormente, se usó el método de mínimos cuadrados, técnica de análisis numérico que permite hallar los coeficientes del polinomio $p(x)$ de grado n de la ecuación (1) que mejor se aproximen a los datos, usando como criterio el error cuadrático medio (MSE) de la ecuación (2), el cual calcula la suma del cuadrado de las diferencias entre los datos reales y_i y los valores estimados por el polinomio $\hat{y}_i$. La figura 5 muestra los resultados de aplicar este proceso usando polinomios de grado 1 (c) y 2 (d).

$$p(x) = p_1 x^n + p_2 x^{n-1} + \ldots + p_n x + p_{n+1} \tag{1}$$

$$MSE = \sum_{i=1}^{m} e_i^2 = \sum_{i=1}^{m} (y_i - \hat{y}_i)^2 \tag{2}$$

En este caso se utilizó mínimos cuadrados, ya que es un método sencillo de implementar que proporciona errores pequeños. También es una de las técnicas más utilizadas para la tarea de regresión lineal.

Usando la máscara del músculo pectoral ajustada con un polinomio, se obtiene la máscara de la imagen sin músculo pectoral, se ajustan los valores de los píxeles negativos para que sean cero y se dilata para suavizar los bordes. Por último, se obtiene la imagen con el músculo pectoral segmentado. La figura 6 ilustra este proceso usando un polinomio de grado 1.

Figura 5

Posprocesamiento del músculo pectoral usando polinomios de grado 1 y 2. (a) Máscara del músculo pectoral utilizando crecimiento de regiones, (b) dilatada, (c) ajustando un polinomio de grado 1, (d) ajustando un polinomio de grado 2

(a) (b) (c) (d)

Figura 6

Imagen con el músculo pectoral segmentado usando un polinomio de grado 1. (a) Máscara de la imagen sin músculo pectoral, (b) imagen con el músculo pectoral segmentado

(a) (b)

3.5. Medidas de desempeño

Para la evaluación del rendimiento se utilizó el coeficiente de similitud de Dice (DSC), dado por la ecuación (3), para medir la semejanza entre la máscara real de la imagen sin músculo pectoral M_r y la máscara obtenida por el método propuesto M. Este coeficiente es una de las formas más comunes de evaluar el proceso de segmentación, mediante la comparación de la similitud entre dos imágenes, donde un valor de 0 indica que no hay superposición entre ellas y un valor de 1 indica una superposición perfecta (Africano et al., 2020). También se utilizó el *accuracy*, dado por la ecuación (4), para medir el porcentaje de píxeles que el algoritmo segmento correctamente, donde TP indica el número de verdaderos positivos, FN los falsos negativos, TN los verdaderos negativos y FP los falsos positivos.

$$DSC = \frac{2 \mid M \cap M_r \mid}{\mid M \mid + \mid M_r \mid} \tag{3}$$

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \tag{4}$$

4. Experimentos y resultados

Esta sección consta de dos etapas: estudio de ablación y resultados de desempeño. En la primera etapa se presenta el proceso de selección del píxel semilla y el umbral utilizados en la técnica de segmentación por crecimiento de regiones presentada en la sección 3.3 y la selección del grado del polinomio utilizado en el posprocesamiento presentado en la sección 3.4. En la segunda etapa se presentan los resultados obtenidos en la evaluación del método propuesto.

Para nuestros experimentos dividimos el conjunto de datos descrito en la sección 3.1, el cual cuenta con 322 mamografías con vista medio lateral oblicua (MLO), en 60 % (193 mamografías) para las pruebas realizadas con el fin de ajustar los parámetros mencionados anteriormente y el 40 % (129 mamografías) para las mediciones del rendimiento del método propuesto.

4.1. Estudio de ablación

Para las secciones 3.3 y 3.4 es necesario elegir los parámetros del píxel semilla, umbral y grado del polinomio, ya que estos son claves para los métodos descritos. Partiendo de esto, se llevaron a cabo múltiples pruebas por variación de parámetros, variando el umbral, el píxel semilla y el grado del polinomio, y se realizó una validación a través del coeficiente de similitud de Dice y el *accuracy*, con el objetivo de seleccionar los valores que proporcionaran las mejores medidas de desempeño.

Para la elección del umbral, con base en la literatura previa y un análisis preliminar de las imágenes, basándonos en la intensidad del tejido mamario y el músculo pectoral, se decidió que el umbral podría alcanzar un valor máximo de 32 y un valor mínimo de 18. Teniendo este rango se

decidió utilizar para las pruebas de selección final del umbral, el umbral máximo de 32, el mínimo de 18 y el valor intermedio entre ellos, 25. Estos valores se eligieron como representativos del rango con el fin de poder observar como van variando las medidas de rendimiento a medida que se varía el umbral dentro de este rango.

Para la elección de la ubicación del píxel semilla, se realizó un análisis preliminar de las imágenes basándonos en el tamaño del músculo pectoral, y se determinó que las coordenadas de este píxel deberían estar entre 1 y 50. Partiendo de esto, para la selección final de los parámetros se llevaron a cabo múltiples pruebas, realizando el proceso de segmentación variando el umbral entre 18, 25 y 32, utilizando valores aleatorios de píxeles semilla que estuvieran entre el rango de 1 a 50. Además, se realizó una validación calculando la media y la desviación estándar del coeficiente de similitud de Dice y el *accuracy* de todas las imágenes, con el fin de determinar el umbral y la ubicación del píxel semilla que presentará los mejores resultados. En la tabla 2, se ilustran algunos de los resultados obtenidos en este proceso para cada uno de los umbrales mencionados anteriormente. Comparando los valores de la media y la desviación estándar de las medidas de desempeño, se eligieron como valores finales un umbral de 18 con un píxel semilla ubicado en [32,5], debido a que con estos valores se presenta la menor desviación estándar y la mayor media, tanto para el *accuracy* como para el coeficiente de similitud de Dice.

Finalmente, habiendo seleccionado el píxel semilla y el umbral, se seleccionó el grado del polinomio que mejor se ajusta a los píxeles del borde del músculo pectoral. Para esto, llevamos a cabo el posprocesamiento descrito en la sección 3.4 usando polinomios de grado 1, 2, 3 y 4. En la tabla 3 se muestran los resultados de este proceso, en el cual se pudo observar que para los

Tabla 2

Medidas de rendimiento variando el umbral y el píxel semilla

Semilla	Media ACC [%]	desviación ACC [%]	Media DSC [%]	desviación DSC [%]
		Para un umbral de 18		
[40,42]	87.84	6.22	87.82	9.09
[5,5]	87.40	7.15	87.65	9.07
[32,5]	87.99	6.17	88.13	8.52
[17,19]	87.46	7.26	87.59	9.39
[9,10]	87.46	7.13	87.75	8.82
		Para un umbral de 25		
[40,42]	87.61	8.06	87.04	11.49
[5,5]	87.18	8.71	86.64	12.04
[32,5]	87.84	7.81	87.27	11.40
[17,19]	87.29	8.67	86.72	12.00
[9,10]	87.28	8.73	86.74	12.04
		Para un umbral de 32		
[40,42]	85.58	12.19	83.87	16.72
[5,5]	85.21	12.37	83.51	16.94
[32,5]	85.88	11.93	84.24	16.47
[17,19]	85.29	12.53	83.58	16.98
[9,10]	85.41	12.25	83.80	16.70

Nota. Esta tabla muestra las medidas de desempeño obtenidas al variar el umbral y el píxel semilla usados en la técnica de crecimiento de regiones.

polinomios de grado 1 y 2 se tienen medidas de desempeño muy similares, por lo que la elección entre estos dos se realizó teniendo en cuenta la poca diferencia que había entre ellos. Partiendo de esto se pudo concluir que el polinomio de grado 1 es el que mejor se ajusta a los datos debido a que para el *accuracy*, se obtiene una media un poco más alta y una desviación estándar un poco menor, utilizando todas las imágenes de prueba.

Tabla 3

Medidas de rendimiento variando el grado del polinomio

Grado del polinomio	Media ACC [%]	desviación ACC [%]	Media DSC [%]	desviación DSC [%]
1	90.16	5.12	90.66	5.86
2	90.15	5.13	90.66	5.85
3	90.18	5.10	90.61	6.02
4	90.06	5.26	90.50	6.26

Nota. Esta tabla muestra las medidas de desempeño obtenidas al variar el grado del polinomio usado en el posprocesamiento.

4.2. Resultados de desempeño

Teniendo definidos los parámetros claves de los métodos de segmentación y posprocesamiento mencionados en las secciones anteriores, se llevo a cabo la evaluación del algoritmo usando el 40 % de las imágenes del conjunto de datos, obteniendo un desempeño final de 88.04 % en el *accuracy* con una desviación estándar del 6.48 % y un coeficiente de similitud de Dice del 89.16 % con una desviación estándar del 6.83 %. La figura 7 ilustra un caso de segmentación exitosa y un caso de falla, donde se pueden observar los resultados a la salida de cada etapa del algoritmo

utilizando los parámetros seleccionados.

El algoritmo propuesto se ejecutó en un entorno de hardware con las siguientes especificaciones: Windows 11, Intel(R) Core(TM) i5-10210U CPU @ 1.60GHz 2.11 GHz y 8 GB de RAM. El tiempo de ejecución fue alrededor de 4 minutos para las 129 imágenes.

Figura 7

Proceso de extracción del músculo pectoral. (a) y (f) Imagen mamográfica original, (b) y (g) preprocesada, (c) y (h) máscara usando crecimiento de regiones, (d) y (i) máscara posprocesada, (e) y (j) sin músculo pectoral

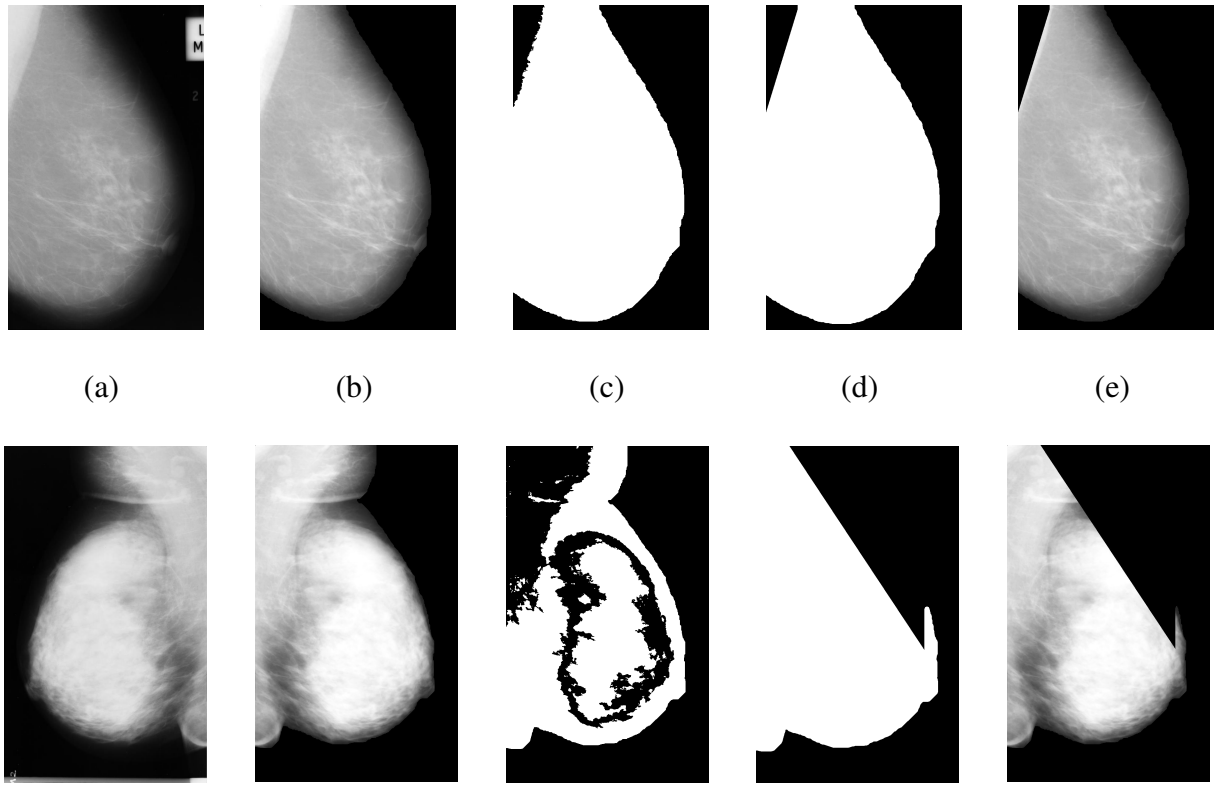

(a) (b) (c) (d) (e)

(f) (g) (h) (i) (j)

5. Discusión y conclusión

Se ha presentado un algoritmo para la segmentación del músculo pectoral en mamografías digitalizadas, el cual incluye una etapa de preprocesamiento para la eliminación de las etiquetas y mejora de la imagen. Posteriormente, se utilizó la técnica de crecimiento de regiones para eliminar el músculo pectoral, siendo [32,5] el píxel semilla y un umbral de 18, los valores con los que se obtuvieron los mejores resultados. Como paso adicional, se realizó un posprocesamiento para mejorar los resultados obtenidos en el paso anterior, ajustando los datos a un polinomio de grado 1, siendo este grado del polinomio el que mejor se adapta a los píxeles del borde del músculo pectoral. Al elegir un valor de píxel semilla y umbral para todo el conjunto de datos, se pudo observar que al probar el algoritmo en imágenes con tejidos densos, en algunos casos, se segmentaba el músculo pectoral y parte del tejido mamario debido a que estos poseen un valor de intensidad muy similar en este tipo de imágenes, esto genera que no se puedan distinguir fácilmente, dificultando el proceso de segmentación. Por lo tanto, este tipo de imágenes necesitaría un umbral menor al del resto para lograr distinguir con más detalle el músculo pectoral del tejido mamario. La figura 7(f)-(j) muestra los resultados de este proceso para este tipo de tejidos. Otro de los motivos que genera problemas en la segmentación se debe a errores presentes en algunas imágenes, los cuales se producen al momento de su digitalización. Estos errores suelen cubrir parte del músculo pectoral, además de poseer un valor de intensidad diferente a este, generando que el algoritmo no logre su segmentación completa. También para algunas imágenes el píxel semilla quedaba ubicado en la región del error, lo cual no permitía la segmentación del músculo pectoral. La figura 3(a) muestra una imagen

que presenta este error en la parte superior. Al comparar el algoritmo con otras investigaciones, este muestra un desempeño aceptable con poca dispersión entre los datos, lo cual es destacable teniendo en cuenta las problemáticas mencionadas anteriormente. Como trabajo futuro, se podrían incorporar técnicas de preprocesamiento que permitan la eliminación del error presente en algunas imágenes. Además, podría incluirse una etapa de extracción de características que permitiera la selección automática del píxel semilla para cada imagen en particular. Por último, podría incluirse un aumento en la base de datos con el objetivo de tener una base de datos más grande que permitiera la utilización de algoritmos de aprendizaje profundo.

Diseñar un algoritmo capaz de segmentar el músculo pectoral en mamografías digitalizadas es una tarea compleja. Partiendo del método de crecimiento de regiones y técnicas clásicas de procesamiento de imágenes, nuestro algoritmo logró superar varios de los retos presentes en la segmentación y eliminación de objetos, alcanzando un rendimiento aceptable, con un coeficiente de similitud de Dice de 89.16 % y un accuracy de 88.04 %, cada uno con una desviación estándar aproximadamente del 6 %. Comparando estos resultados con trabajos anteriores, los valores son considerados cercanos. Por lo tanto, este algoritmo podría ser una herramienta de apoyo en las etapas de preprocesamiento de los sistemas CAD.

Bibliografía

Africano, G., Arponen, O., Sassi, A., Rinta-Kiikka, I., Lääperi, A.-L., & Pertuz, S. (2020). A New Benchmark and Method for the Evaluation of Chest Wall Detection in Digital Mammography. *2020 42nd Annual International Conference of the IEEE Engineering in Medicine Biology Society (EMBC)*, 1132-1135. https://doi.org/10.1109/EMBC44109.2020.9175960

Chevalier, M., & Torres, R. (2010). Mamografía digital. *Revista de Física Médica*, *11*(1). https://revistadefisicamedica.es/index.php/rfm/article/view/90

Elmoufidi, A. (2019). Pre-Processing Algorithms on Digital X-ray Mammograms. *2019 IEEE International Smart Cities Conference (ISC2)*, 87-92. https://doi.org/10.1109/ISC246665.2019.9071750

Ganesan, K., Acharya, U. R., Chua, K. C., Min, L. C., & Abraham, K. T. (2013). Pectoral muscle segmentation: A review. *Computer Methods and Programs in Biomedicine*, *110*(1), 48-57. https://doi.org/https://doi.org/10.1016/j.cmpb.2012.10.020

Hamissi, S., & Merouani, H. F. (2012). Novel fully automated Computer Aided-Detection of suspicious regions within mammograms. *Second International Conference on the Innovative Computing Technology (INTECH 2012)*, 153-157. https://doi.org/10.1109/INTECH.2012.6457756

Liu, W., Liu, C., & Wei, Y. (2020). Utilizing Deep Learning Technology to Segment Pectoral Muscle in Mediolateral Oblique View Mammograms. *2020 IEEE 5th International Conference*

on Signal and Image Processing (ICSIP), 97-101. https://doi.org/10.1109/ICSIP49896.2020.9339411

Majeed, T. F., Al-Jawad, N., & Sellahewa, H. (2013). Breast border extraction and pectoral muscle removal in MLO mammogram images. *2013 5th Computer Science and Electronic Engineering Conference (CEEC)*, 119-124. https://doi.org/10.1109/CEEC.2013.6659457

Moghbel, M., Ooi, C.-Y., Ismail, N., Hau, Y., & Memari, N. (2020). A review of breast boundary and pectoral muscle segmentation methods in computer-aided detection/diagnosis of breast mammography. *Artificial Intelligence Review*, *53*. https://doi.org/10.1007/s10462-019-09721-8

Nagi, J., Abdul Kareem, S., Nagi, F., & Khaleel Ahmed, S. (2010). Automated breast profile segmentation for ROI detection using digital mammograms. *2010 IEEE EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, 87-92. https://doi.org/10.1109/IECBES.2010.5742205

Naz, S. I., Shah, M., & Bhuiyan, M. I. H. (2017). Automatic Segmentation of Pectoral Muscle in Mammogram Images Using Global Thresholding and Weak Boundary Approximation. *2017 IEEE International WIE Conference on Electrical and Computer Engineering (WIECON-ECE)*, 199-202. https://doi.org/10.1109/WIECON-ECE.2017.8468895

Oliver, A., Lladó, X., Torrent, A., & Martí, J. (2014). One-shot segmentation of breast, pectoral muscle, and background in digitised mammograms. *2014 IEEE International Conference on Image Processing (ICIP)*, 912-916. https://doi.org/10.1109/ICIP.2014.7025183

Pertuz, S., Torres, G. F., Tamimi, R., & Kamarainen, J. (2019). Open Framework for Mammography-based Breast Cancer Risk Assessment. *2019 IEEE EMBS International Conference on Biomedical Health Informatics (BHI)*, 1-4. https://doi.org/10.1109/BHI.2019.8834599

Rahmatika, A., Handayani, A., & Setiawan, A. W. (2019). Automated Segmentation of Breast Tissue and Pectoral Muscle in Digital Mammography. *2019 International Conference of Artificial Intelligence and Information Technology (ICAIIT)*, 397-401. https://doi.org/10.1109/ICAIIT.2019.8834455

Rampun, A., López-Linares, K., Morrow, P. J., Scotney, B. W., Wang, H., Ocaña, I. G., Maclair, G., Zwiggelaar, R., González Ballester, M. A., & Macía, I. (2019). Breast pectoral muscle segmentation in mammograms using a modified holistically-nested edge detection network. *Medical Image Analysis*, *57*, 1-17. https://doi.org/https://doi.org/10.1016/j.media.2019.06.007

Saltanat, N., Hossain, M. A., & Alam, M. S. (2010). An efficient pixel value based mapping scheme to delineate pectoral muscle from mammograms. *2010 IEEE Fifth International Conference on Bio-Inspired Computing: Theories and Applications (BIC-TA)*, 1510-1517. https://doi.org/10.1109/BICTA.2010.5645272

Wang, K., Khan, N., Chan, A., Dunne, J., & Highnam, R. (2019). Deep Learning for Breast Region and Pectoral Muscle Segmentation in Digital Mammography. En C. Lee, Z. Su & A. Sugimoto (Eds.), *Image and Video Technology* (pp. 78-91). Springer International Publishing.

Zhou, K., Li, W., & Zhao, D. (2022). Deep learning-based breast region extraction of mammographic images combining pre-processing methods and semantic segmentation supported

by Deeplab v3 [Cited by: 1; All Open Access, Bronze Open Access, Green Open Access]. *Technology and Health Care*, *30*(S1), S173-S190. https://doi.org/10.3233/THC-228017