

Detección de la Distorsión de la Arquitectura de la Glándula Mamaria a partir de Imágenes Radiológicas: Una aproximación desde la lógica difusa

Duván Alberto Gómez Betancur¹, John Willian Branch Bedoya²

¹Grupo GIDIA, Facultad de Minas, Universidad Nacional de Colombia
dagomezbe@unal.edu.co

² Investigador Grupo GIDIA, Profesor Asociado, Facultad de Minas Universidad Nacional de Colombia
jwbranch@unal.edu.co

Keywords: Breast Cancer, Architectural Distortion, Mammography, Digital Image Processing, Computer Aided Diagnosis.

Abstract

Architectural distortion is an abnormal change in the mammary gland tissue followed by a formation of fine and speculated lesions that are not associated with the presence of a mass. It is the first cause of false-negative findings on screening mammograms, due to its subtlety. This paper outlines a new method for the detection of architectural distortion in the mammary gland from breast radiology images. This method could assist the specialists in the diagnosis of breast cancer through four main phases, which encompass from the preprocessing to the classification of regions of interest using a classifier based on fuzzy logic.

The method described in this paper was validated through the analysis of mammographic images from DDSM (Digital Database for Screening Mammography) obtaining values of 90.7% in the overall accuracy.

Palabras Clave: Cáncer de Mama, Distorsión de la Arquitectura, Mamografía, Procesamiento Digital de Imágenes, Diagnóstico Asistido por Computador.

Resumen

La distorsión de la arquitectura es un cambio anormal del tejido de la glándula mamaria con la consiguiente formación de lesiones finas y espiculadas que no están asociadas con la presencia de una masa. Debido a su sutileza es la primera causa de falsos negativos en las mamografías de tamizaje. En este artículo se describe un nuevo método para la detección de la distorsión de la arquitectura de la glándula mamaria a partir de imágenes de radiología de mama. El método propuesto comprende cuatro fases principales, que cubren desde el preprocesamiento hasta la clasificación de las regiones de interés utilizando un clasificador basado en lógica difusa.

El método descrito se validó a través del análisis de imágenes mamográficas de la base de datos DDSM (Digital Database for Screening Mammography) logrando valores superiores al 90% en la precisión general.

1 Introducción

Las imágenes juegan un rol prominente en los ambientes médicos apoyando el diagnóstico y tratamiento de enfermedades debido a que permiten que los especialistas obtengan información vital observando el interior del cuerpo humano de una forma no invasiva, y favoreciendo el diagnóstico temprano de patologías para que puedan ser tratadas de manera efectiva [1] como es el caso del cáncer de mama o cáncer de seno que consiste en el crecimiento no controlado de las células de la mama formando un tumor maligno.

En el mundo el cáncer de mama es una patología cada vez más común entre la población femenina, por ejemplo para el caso de Estados Unidos y Canadá, se estima que 1 de cada 8 mujeres sufrirá la enfermedad a lo largo de su vida, y en el 2006 se calcularon 212.920 nuevos casos de cáncer de mama y 41.430 muertes producidas por la enfermedad [17].

La mamografía es el examen más eficaz para la detección temprana del cáncer de mama y los hallazgos clínicos más comunes que pueden indicar el desarrollo de una patología cancerígena en la mama y que deben tratar de identificarse con gran precisión al analizar una mamografía son: Masas, Microcalcificaciones, Distorsiones de la Arquitectura y Asimetrías de Densidad, pues son los que se presentan con más regularidad y son signos de alarma visibles y en algunos casos palpables, de la presencia o posible desarrollo de un cáncer de mama.

Las *calcificaciones* son hallazgos muy comunes en una mamografía y son consecuencias de diminutos depósitos de calcio en el tejido mamario. En cuanto a las *masas* debe describirse su tamaño, forma, márgenes y calcificaciones asociadas en los casos en los que la masa se presente con calcificaciones. Por su parte la *asimetría de densidad* es la presencia de tejido glandular en una parte de la mama y que no se presenta con la misma localización en la mama contralateral, puede verse como una opacidad similar en las dos proyecciones de una mama pero no tiene características de una masa [2].

2 Distorsión de la arquitectura

La distorsión de la arquitectura es un cambio anormal del tejido de la glándula mamaria con la consiguiente formación de lesiones finas y espiculadas que no están asociadas a la presencia de una masa.

En el BI-RADS [3] se define la distorsión de la arquitectura como: “La arquitectura normal (de la mama) se distorsiona con masas no definidas visibles. Esto incluye espiculaciones que irradian de un punto y retracción focal o distorsión en el borde del parénquima. La distorsión de la arquitectura puede ser también un hallazgo asociado...”

Se trata del tercer hallazgo más común en mamografías, asociado a estados de cáncer aún no palpables [4] y el primer causante de falsos negativos [5] pues debido a su sutileza y variabilidad, la distorsión de la arquitectura es omitida y puede pasar como tejido normal superpuesto en el momento de la valoración de las mamografías de tamizaje.

De acuerdo con [6] en más de la mitad de los casos en los cuales se han encontrado signos de distorsión de la arquitectura se comprueba posteriormente malignidad en el seno. Sin embargo por la dificultad en la detección de la distorsión de la arquitectura, se estima que esta anomalía es la causa de entre el 12% y el 45% de los casos de cáncer omitidos o mal interpretados [7].

Si bien es cierto que son muchos los trabajos que se pueden encontrar en sistemas CAD (Sistemas de Diagnóstico Asistido por Computador) para el caso de cáncer de mama, también es cierto que mientras la gran mayoría han sido dirigidos a la detección y análisis de calcificaciones y masas [8][9][10][11], relativamente pocos han sido publicados en la detección de la distorsión de la arquitectura de la glándula mamaria.

Entre los trabajos más destacados para la detección de la distorsión de la arquitectura de la glándula mamaria se encuentra la investigación descrita en [12], donde se usa morfología matemática para detectar distorsión alrededor de la línea de piel y un índice de concentración para detectar distorsión de arquitectura al interior de la glándula mamaria obteniendo tasas de sensibilidad superiores al 80%; en [13] se desarrolló un método para detectar masas y distorsión de arquitectura localizando puntos rodeados por capas concéntricas. En [14] se presenta una investigación para la caracterización de la distorsión de arquitectura usando la dimensión fractal de Hausdorff y un clasificador SVM (Support Vector Machine) para distinguir entre ROIs (Regiones de Interés) con distorsión de arquitectura y ROIs con patrones mamográficos normales, una clasificación con una precisión del 72.5% fue obtenida con un conjunto de 40 ROIs.

También se han publicado trabajos en los cuales a partir de filtros Gabor y análisis de dimensión fractal se proponen métodos para detectar candidatos iniciales de distorsión de la arquitectura en mamografías [15], [16].

Rangayyan en [17] utilizando características de textura de Haralick, comparó diferentes técnicas de clasificación. A partir de 4.224 ROIs obtuvo una sensibilidad de 76% con un clasificador bayesiano, 73% con análisis discriminante lineal,

77% con una red neuronal artificial basada en funciones de base radial y una sensibilidad de un 77% con SVM.

3 Detección de distorsiones de la arquitectura de la glándula mamaria

A continuación se presenta un nuevo método para asistir la detección de la distorsión de la arquitectura de la glándula mamaria a partir de imágenes radiológicas y mediante el uso de un sistema de decisión basado en lógica difusa.

Con base en el método propuesto por Rangayyan en [17], inicialmente se realiza una etapa de preprocesamiento para lograr la reducción del área de trabajo y la disminución de ruido en la imagen. Posteriormente se aplica el filtro de Gabor sobre la imagen mamográfica para detallar la información de orientación de la arquitectura de la glándula mamaria y con el resultado obtenido a partir del filtro de Gabor, se realiza el análisis de retrato de fase para encontrar un conjunto de ROIs a las cuales se les extraen las características de textura propuestas por Haralick [18]. Finalmente se utiliza un sistema de decisión difuso para la determinación de las áreas con presencia de distorsión de la arquitectura de la glándula mamaria.

3.1 Detección de ROIs

Conocer las características de orientación de los objetos contenidos dentro de la imagen mamográfica permite identificar si la orientación de los tejidos es diferente a la dirección normal hacia el pezón.

Para extraer la información visual de orientación de los tejidos al interior de la glándula mamaria en la imagen, se utiliza el método propuesto en [17] en el cual se utiliza la parte real del Filtro de Gabor.

Se generan 180 máscaras del filtro de Gabor en orientaciones diferentes comprendidas entre $-\pi/2$ y $\pi/2$ con una diferencia de un grado entre ellas y se procesa la mamografía con cada una para obtener la respuesta en magnitud. La información de orientación se obtiene a partir del ángulo del filtro de Gabor que produzca la mayor respuesta en cada punto de la imagen.

Los datos de los ángulos obtenidos a partir del filtro de Gabor representan el campo de orientación de los tejidos de la glándula mamaria dentro de la mamografía analizada y a través de una ventana de análisis de tamaño 10x10 centrada en cada píxel, ese campo de orientación puede ser aproximado al retrato de fase de un sistema de ecuaciones diferenciales de primer orden como se observa en la Ecuación (1).

$$\phi(x, y|A, b) = \arctan\left(\frac{a_{11} * x + a_{12} * y + b_{11}}{a_{21} * x + a_{22} * y + b_{21}}\right) \quad (1)$$

con

$$A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \quad y \quad b = \begin{bmatrix} b_{11} \\ b_{21} \end{bmatrix}$$

donde ϕ representa el ángulo calculado en el modelo para retrato de fase y \mathbf{A} y \mathbf{b} se calculan a partir de la minimización de la Ecuación (2) que es la diferencia existente entre θ que es el ángulo calculado con el filtro de Gabor y ϕ que es el ángulo

estimado en el modelo a partir de la aproximación al sistema de ecuaciones diferenciales.

$$\Delta(\theta, \phi) = \frac{1}{2} * \text{sen} \left[\theta - \arctan \left(\frac{a_{11} * x + a_{12} * y + b_{11}}{a_{21} * x + a_{22} * y + b_{21}} \right) \right] \quad (2)$$

A partir de la matriz A y con el cálculo de sus eigenvalores, se define el tipo de retrato de fase identificado en cada píxel [17]. Con los puntos en los cuales se identifique un retrato de fase tipo nodo se construye una imagen denominada mapa de nodos y en la cual esos puntos identificados se marcan en color blanco para diferenciarlos del fondo negro.

Finalmente, en el método propuesto en este artículo se realiza una modificación sobre la propuesta de Rangayyan [17] y se aplica una operación morfológica de cerrado sobre el mapa de nodos con el fin de disminuir el número de falsos positivos y ubicar las regiones en las cuales se encuentre la mayor cantidad de puntos para marcarlas como regiones candidatas a la presencia de distorsión de la arquitectura o regiones de interés.

3.2 Características de textura

En un gran número de aplicaciones de procesamiento digital de imágenes la textura es una de las características más importantes y utilizadas para la recuperación de información y la identificación de objetos o regiones al interior de la imagen.

Para Haralick, [18] las propiedades de tono y textura están siempre presentes en una imagen, y el procedimiento que sugiere para obtener las características de textura se basa en la presunción que la información de textura de una imagen definida, está contenida en la totalidad o por lo menos el promedio de la relación espacial que los tonos de grises de la imagen tienen el uno con el otro. Es decir, esa información de textura está adecuadamente contenida en un conjunto de matrices espacio-dependientes de los tonos de gris, las cuales son calculadas para diferentes ángulos y distancias de vecindad en los píxeles de la imagen y son conocidas como GCM (Graylevel Co-Occurrence Matrix).

La GCM se construye con las probabilidades de ocurrencia de un par de niveles de gris (l_1, l_2) separados por una distancia d en un ángulo θ [18]. Es decir, dada una imagen I con N niveles de gris, su GCM para un ángulo θ , se construye con N filas y N columnas, y en cada intersección fila-columna se totaliza el número de veces dentro de la imagen en las cuales un punto $I(x,y)$ con un nivel de gris l_1 (de acuerdo con la columna de la GCM) posee un vecino en una distancia d y en la dirección θ con un nivel de gris l_2 (de acuerdo con la fila de la GCM).

A partir de la GCM, Haralick propone catorce características de textura, sin embargo en este trabajo se utilizan solo cinco de ellas: energía, contraste, suma promedio, momento de diferencia inversa y diferencia de varianza, ya que de acuerdo con [17] son esas características las que empaquetan no solo la mayor cantidad de información visual, sino también la más relevante para la descripción de la textura de las regiones de interés.

3.3 Sistema de decisión basado en lógica difusa

Los valores calculados de las características de textura de Haralick de las regiones de interés detectadas se utilizan para la identificación, clasificación y determinación final de las áreas con presencia de distorsión de la arquitectura de la glándula mamaria utilizando un clasificador basado en lógica difusa.

El uso de la lógica difusa resulta bastante útil en problemas con alto grado de incertidumbre y donde se necesita usar el conocimiento de un experto que utiliza conceptos ambiguos o imprecisos, por ello se ha visto un auge en su uso en sistemas de reconocimiento de patrones y visión por computador.

Los componentes principales de un sistema de decisión de lógica difusa son: los conjuntos difusos, las funciones de membresía o pertenencia difusas y las reglas difusas [19].

En el método propuesto en este documento, se utilizan funciones de pertenencia con distribución gaussiana, es decir, en forma de campana de Gauss.

Así, si se considera x una característica de textura cualquiera que puede ser medida sobre una imagen. Si μ es la media de los valores de x definidos para un conjunto de imágenes dentro de una misma categoría y σ es la desviación estándar del conjunto de valores de x , los parámetros μ y σ se utilizan para definir con detalle las funciones de pertenencia a las clases normal o anormal para cada una de las medidas de textura calculadas.

Se generan diez funciones de pertenencia, cinco para cada una de las características de textura utilizadas para el caso normal y cinco para cada una de las cinco características de textura utilizadas para el caso anormal.

En el método propuesto se utilizan reglas difusas simples de la forma:

Si x_i es c_{i1} y, ..., x_m es c_{m1} entonces y es w_i

donde i es el número de la regla analizada (con $i=1,2,\dots,N$ para N reglas), x_1, \dots, x_m son variables de entrada para el clasificador difuso, y es la salida del clasificador difuso, c_{i1}, \dots, c_{im} son etiquetas difusas correspondientes a las variables de entrada, y w_i es un número real del consecuente de la regla difusa.

Las reglas difusas utilizadas son:

Regla (1): Si (El valor de energía es la media de los valores de energía de los casos normales) y (El valor de contraste es la media de los valores de contraste de los casos normales) y (El valor de suma promedio es la media de los valores de suma promedio de los casos normales) y (El valor del momento de diferencia inversa es la media de los valores de momento de diferencia inversa de los casos normales) y (El valor de diferencia de varianza es la media de los valores de diferencia de varianza de los casos normales), entonces el caso es clasificado como normal con 99.9% de certeza.

Regla (2): Si (El valor de energía es la media de los valores de energía de los casos anormales) y (El valor de contraste es la media de los valores de contraste de los casos

anormales) y (El valor de suma promedio es la media de los valores de suma promedio de los casos anormales) y (El valor del momento de diferencia inversa es la media de los valores de momento de diferencia inversa de los casos anormales) y (El valor de diferencia de varianzas es la media de los valores de diferencia de varianzas de los casos anormales), entonces el caso es clasificado como anormal con 99.9% de certeza.

Estas dos reglas se pueden observar en la Fig. 1.




Figura 1: Reglas Difusas Utilizadas

Para el proceso de defusificación se utiliza el método de centro de gravedad tradicionalmente utilizado. La función utilizada en la parte del consecuente del sistema de decisión difuso, es un triángulo isósceles normalizado como se observa en la Fig.2.

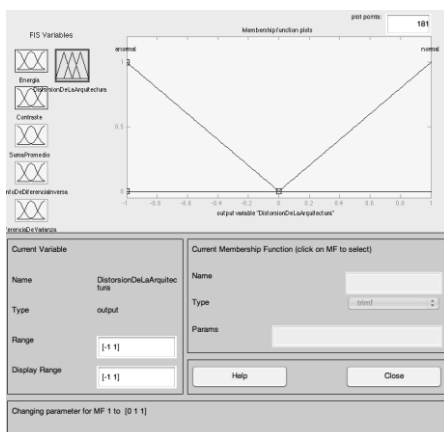


Figura 2: Conjuntos de Salida del Sistema de Decision Difuso

4 Resultados

El comportamiento del método se evalúa en términos de la sensibilidad, especificidad y precisión general. La precisión general es la probabilidad de que el diagnóstico emitido por el método sea correcto y acorde con la situación real del paciente [19].

En el método propuesto se definen cinco variables de entrada correspondientes a las medidas de las cinco características de textura de Haralick seleccionadas en la investigación, como se observa en la Fig. 3.

Asimismo, como se mencionó anteriormente para cada una de las variables de entrada se definen dos funciones de

pertenencia correspondientes a los casos normal y anormal, como se puede observar en el ejemplo de la Fig.4.




Figura 3: Sistema de Decisión Basado en Lógica Difusa Implementado

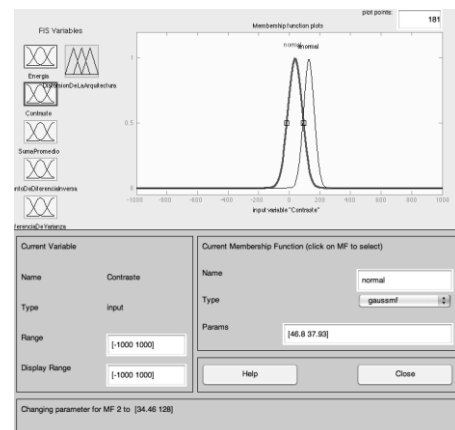


Figura 4: Ejemplo de la Variable de Entrada de la Característica de Contraste al Sistema de Decisión y las Funciones de Pertenencia Asociadas a la Misma

Con las ROIs identificadas, la extracción de las características de textura de las mismas y la clasificación con un sistema de decisión basado en lógica difusa para asociarlas a las clases anormal o normal según presentaran o no distorsión de la arquitectura de la glándula mamaria respectivamente, se encuentran valores significativos en la precisión general del método, como se registra en la Tabla 1.

VP	FP	VN	FN
44	12	112	4

Tabla 1: Total de Verdaderos Positivos (VP), Falsos Positivos (FP), Verdaderos Negativos (VN) y Falsos Negativos (FN) Obtenidos en una Prueba

A partir de los datos de la Tabla 1 se pueden calcular los siguientes valores para las variables de comportamiento: Sensibilidad 91.7%, Especificidad 90.3% y Precisión General 90.7%, lo cual demuestra que una vez son extraídas las características de textura y se realiza la clasificación con el sistema de decisión difuso aunque se presentan algunos falsos negativos, los valores de especificidad y precisión general del método son bastante significativos.

De esa manera los valores de las tres medidas de comportamiento del método propuesto superan el 90% de precisión general lo cual hace de este método una herramienta

de apoyo para la detección de distorsiones de la arquitectura de la glándula mamaria comparable con los trabajos publicados por otros autores, sin embargo realizar un análisis comparativo a niveles más detallados resulta bastante difícil ya que en cada investigación reportada los conjuntos de datos e imágenes varían de un trabajo a otro.

5 Conclusiones

Los resultados del desempeño del método demuestran que debido al grado de incertidumbre inmerso en los diagnósticos que se hacen a partir de las radiologías de mama, el uso de un sistema de decisión diferente a los clasificadores clásicos reportados en el estado del arte, como el caso del sistema de decisión basado en lógica difusa implementado en el presente estudio, permite alcanzar niveles de precisión general cercanos a un 90%. Lo cual, considerando que se utilizó una base de datos de dominio público como lo es la base DDSM [20], hace del método propuesto una línea base de investigación en el tema de la detección de distorsiones de la arquitectura de la glándula mamaria.

Asimismo, el método presentado puede ser usado en diferentes escenarios clínicos para diagnóstico y seguimiento de patologías donde se presente alteración de la distribución normal de tejidos como por ejemplo en el tratamiento y evolución de quemaduras. Además, teniendo en mente los resultados obtenidos para la detección de la distorsión de la arquitectura de la glándula mamaria, puede plantearse la extensión del método para la detección de otras anomalías de la mama que pueden ser vistas a través de la mamografía como las microcalcificaciones, las masas y las asimetrías de densidad.

Por otra parte, aunque las pruebas realizadas muestran resultados de precisión superiores al 90%, es importante una segunda validación utilizando, por ejemplo, un conjunto de imágenes diferente a la base de datos DDSM [20] que permita evaluar con más precisión el comportamiento del método propuesto.

Con el fin de mejorar los resultados del clasificador difuso es posible realizar un proceso de afinación de las funciones de pertenencia propias de los conjuntos difusos propuestas en este documento, a través del afinamiento de los parámetros de dichas funciones de pertenencia aplicando por ejemplo algoritmos genéticos como se sugiere en [19]

Finalmente, el método de detección de distorsiones de la arquitectura de la glándula mamaria desarrollado, resulta ser una base importante para la investigación aplicada, ya que los resultados obtenidos a nivel de precisión general hacen posible que se pueda llevar a un entorno real y encontrar aplicación local o regional incluso ampliando el alcance del mismo método, para que además de asistir a los radiólogos en el momento de la evaluación de las mamografías, también sirva como herramienta de entrenamiento de nuevos especialistas y como instrumento para la medición de la calidad del servicio diagnóstico prestado por los radiólogos ya expertos

Referencias

- [1] E. Coto, «Método de Segmentación de Imágenes Médicas», *Lecturas en Ciencias de la Computación*. Universidad Central de Venezuela. ISSN 1316-6239, 2003.
- [2] F. R. Narváez E., «Sistema de Anotación para Apoyo en el Seguimiento y Diagnóstico de Cáncer de Seno», Universidad Nacional de Colombia, 2010.
- [3] American College of Radiology (ACR), *Breast Imaging Reporting and Data System*, 4th ed. 2003.
- [4] A. M. Knutzen y J. J. Gisvold, «Likelihood of malignant disease for various categories of mammographically detected, nonpalpable breast lesions.», in *Mayo Clinic proceedings*. *Mayo Clinic*, 1993, vol. 68, p. 454.
- [5] S. Banik, R. M. Rangayyan, y J. E. L. Desautels, «Detection of Architectural Distortion in Prior Mammograms», *Medical Imaging, IEEE Transactions on*, vol. 30, n.º. 2, pp. 279–294, 2011.
- [6] T. Matsubara, T. Ichikawa, T. Hara, H. Fujita, S. Kasai, T. Endo, y T. Iwase, «Novel method for detecting mammographic architectural distortion based on concentration of mammary gland», in *International Congress Series*, 2004, vol. 1268, pp. 867–871.
- [7] B. C. Yankaskas, M. J. Schell, R. E. Bird, y D. A. Desrochers, «Reassessment of breast cancers missed during routine screening mammography: a community-based study», *American Journal of Roentgenology*, vol. 177, n.º. 3, p. 535, 2001.
- [8] M. Bustamante, G. Lefranc, A. Núñez, y M. G. Pesce, «Calculo De La Amplitud Dispersada En Mamografías, Usando Como Modelo De Degradacion El Filtro Bosso.», *PHAROS*, vol. 8, n.º. 1, 2001.
- [9] H. D. Cheng, X. J. Shi, R. Min, L. M. Hu, X. P. Cai, y H. N. Du, «Approaches for automated detection and classification of masses in mammograms», *Pattern Recognition*, vol. 39, n.º. 4, pp. 646–668, 2006.
- [10] J. Tang, R. M. Rangayyan, J. Xu, I. El Naqa, y Y. Yang, «Computer-aided detection and diagnosis of breast cancer with mammography: Recent advances», *Information Technology in Biomedicine, IEEE Transactions on*, vol. 13, n.º. 2, pp. 236–251, 2009.
- [11] R. M. Rangayyan y T. M. Nguyen, «Fractal Analysis of Contours of Breast Masses in Mammograms», *Journal of Digital Imaging*, vol. 20, pp. 223–237, oct. 2006.
- [12] T. Matsubara, T. Ichikawa, T. Hara, H. Fujita, S. Kasai, T. Endo, y T. Iwase, «Automated detection methods for architectural distortions around skinline and within mammary gland on mammograms», *International Congress Series*, vol. 1256, pp. 950–955, jun. 2003.
- [13] N. Eltonsy, G. D. Tourassi, y A. Elmaghraby, «Investigating performance of a morphology-based CAD scheme in detecting architectural distortion in screening mammograms», *Proc. 20th Int. Congr. Exhib. Comput. Assist. Radiol. Surg.*, pp. 336–338, 2006.
- [14] G. D. Tourassi, D. M. DeLong, y C. E. Floyd, «A study on the computerized fractal analysis of architectural distortion in screening mammograms», *Physics in Medicine and Biology*, vol. 51, pp. 1299–1312, mar. 2006.
- [15] R. M. Rangayyan, S. Prajna, F. J. Ayres, y J. E. L. Desautels, «Detection of architectural distortion in prior screening mammograms using Gabor filters, phase portraits, fractal dimension, and texture analysis», *International Journal of Computer Assisted Radiology and Surgery*, vol. 2, n.º. 6, pp. 347–361, 2008.

- [16] S. Prajna, R. M. Rangayyan, F. J. Ayres, y J. E. L. Desautels, «Detection of architectural distortion in mammograms acquired prior to the detection of breast cancer using texture and fractal analysis», in *Proceedings of SPIE*, 2008, vol. 6915, p. 691529.
- [17] R. M. Rangayyan, S. Banik, y J. E. L. Desautels, «Computer-aided detection of architectural distortion in prior mammograms of interval cancer», *Journal of Digital Imaging*, vol. 23, n^o. 5, pp. 611–631, 2010.
- [18] R. M. Haralick, K. Shanmugam, y I. Dinstein, «Textural Features for Image Classification», *IEEE Transactions on Systems, Man and Cybernetics*, vol. 3, n^o. 6, pp. 610–621, nov. 1973.
- [19] D.-Y. Tsai y K. Kojima, «Measurements of texture features of medical images and its application to computer-aided diagnosis in cardiomyopathy», *Measurement*, Volume 37, Issue 3, April 2005, Pages 284–292.
- [20] Michael Heath, Kevin Bowyer, Daniel Kopans, Richard Moore, and W. Philip Kegelmeyer. The digital database for screening mammography. in *Proceedings of the Fifth International Workshop on Digital Mammography*, Medical Physics Publishing, M.J. Yaffe, ed:212-218, 2001.