

Envío: 17-06-2013

Aceptación: 30-06-2013

Publicación: 30-08-2013

# COMBINACIÓN DE TÉCNICAS DE PROCESAMIENTO DIGITAL DE IMÁGENES E INTELIGENCIA ARTIFICIAL PARA EL ANÁLISIS DE IMÁGENES DE MAMOGRAFÍA

---

## COMBINATION OF DIGITAL PROCESSING TECHNIQUES OF IMAGES AND ARTIFICIAL INTELLIGENCE FOR THE ANALYSIS OF MAMMOGRAM IMAGES

Alejandro Díaz Sotolongo<sup>1</sup>

Danays Barbara Costa Alonso<sup>2</sup>

1. Máster, Ingeniero Informático. Profesor del Departamento de Ciencias Informáticas, UNICA.
2. Ingeniero Informático. Profesora del Departamento de Matemática, UNICA.

## RESUMEN

Este artículo propone un nuevo algoritmo capaz de realizar la detección/clasificación de lesiones patológicas como un todo, combinando parámetros de forma y textura en la formación de vectores de características representativos. La implementación del algoritmo se realizó en MATLAB, el cual fue validado en un conjunto de imágenes de mamografías pertenecientes a la base de datos de dominio público MiniMIAS. Los resultados obtenidos por un conjunto de clasificadores demuestran la efectividad del algoritmo propuesto, así como la calidad de los vectores de características desarrollados.

## ABSTRACT

This paper proposes a new algorithm able to carry out the detection/classification of pathological lesions as a whole, combining shape and texture parameters in the formation of representative features vectors. The implementation of the algorithm was carried out in MATLAB, which was validated in a group of mammogram images belonging to the database of public domain MiniMIAS. The obtained results by a group of classifiers, demonstrate the effectiveness of the proposed algorithm, as well as the quality of the developed features vectors.

## PALABRAS CLAVE

Forma, textura, vectores de características, clasificadores.

## KEY WORDS

Shape, texture, features vectors, classifiers.

## INTRODUCCIÓN

El cáncer de mama constituye una de las principales causas de muerte entre mujeres [1]. De acuerdo con las estadísticas publicadas, se ha convertido en un problema de salud importante a escala mundial durante los últimos 50 años [2]. En la actualidad, no existen mecanismos eficaces para prevenirlo, debido a que la causa de origen es desconocida. Sin embargo, un diagnóstico eficaz en su etapa inicial les brinda a las mujeres una mejor oportunidad de recuperación completa. Por tanto, la detección temprana del cáncer de mama juega un papel importante en la reducción de la morbilidad y mortalidad.

La lectura de mamografías es la primera modalidad de técnica de detección del cáncer de mama, debido a que es el único método de análisis de imágenes de mamografías que consistentemente ha demostrado disminuir las tasas de mortalidad por cáncer de mama. La mamografía es ampliamente utilizada y es una de las técnicas más confiables, ya que podría detectar el cáncer de mama antes de que este aparezca clínicamente [3].

La doble lectura de mamografías (dos radiólogos leen las mismas mamografías) [4] ha sido recomendada para reducir la proporción de posibles tumores no detectados, pero la carga de trabajo y los costos asociados son muy elevados. Sin embargo, con la introducción de los sistemas de Diagnóstico Asistido por Computadoras (CAD), sólo es necesario el empleo de un radiólogo.

Los sistemas CAD, los cuales utilizan las tecnologías informáticas en la detección de anomalías en imágenes de mamografías y el empleo de los resultados obtenidos por los radiólogos en el diagnóstico [5], constituyen un papel fundamental en la detección precoz del cáncer de mama. Durante los últimos años, los sistemas CAD y las técnicas relacionadas han sido objetos de estudio de investigadores y radiólogos.

Para los investigadores existen varios temas de interés relacionados con la detección del cáncer y los sistemas CAD, tales como: alta eficiencia y alta precisión en los algoritmos de detección de lesiones patológicas (calcificaciones, masas, distorsiones de la arquitectura y asimetrías bilaterales). Por otra parte, los radiólogos inclinan su atención a la efectividad obtenida por la aplicación clínica de los sistemas CAD.

## REVISION DE LA LITERATURA

### Métodos para la detección de Microcalcificaciones (MCs)

Las MCs son los primeros signos de cáncer de mama, apareciendo en las imágenes de mamografías como pequeños y brillantes puntos incrustados dentro del fondo. Los métodos de detección de MCs podrían ser divididos en las siguientes categorías: mejoramiento de imagen, extracción de características y máquinas de aprendizaje.

### Mejoramiento de imagen

Nishikawa, Giger y el colectivo de autores, desarrollaron un método de mejoramiento de imagen basado en una técnica de filtrado [6]. Otro ejemplo es el método presentado por Jeffrey, Liang y el colectivo de autores. Este método implementa un conjunto de filtros basados en propiedades geométricas y topológicas de las MCs a través de la rotación, reflexión y traslación [7]. En el trabajo desarrollado por Linguraru, Marias y su colectivo de autores, propusieron un método basado en la combinación entre un modelo visual y un filtrado de difusión anisotrópica. Además, se utilizó una operación morfológica para reducir los Falsos Positivos en el post-procesamiento mejorando la sensibilidad al ruido [8].

### Extracción de características

Dependiendo del tipo de características que se extraigan de la imagen, el espacio de características puede dividirse en tres categorías: características de intensidad, características geométricas y características de textura.

En la investigación desarrollada por Hamid, Farshid y su colectivo de autores, se comparó el desempeño de cuatro conjuntos de características: características basadas en matrices de coocurrencia, descriptores de forma de las MCs, wavelet, y características multiwavelet [9]. Isaac, Richard y su colectivo de autores desarrollaron un método que emplea las características reflejadas de la arquitectura interna de un clúster de MC [4]. Autores como Liang, Rangayyan y otros, propusieron un conjunto de características de forma a partir de MCs individuales, alcanzando un 100% de exactitud en la clasificación [10]. En otro trabajo Veldkamp utilizó un clúster de características obtenidas a partir de la forma, la posición y la distribución en la clasificación de MCs [11]. Lee, Chung y su colectivo de autores, diseñaron una Red Neuronal Artificial (ANN) basada en el reconocimiento de la forma para la captura de la información geométrica de las MCs [12]. Papadopoulos, Fotiadis y su colectivo de autores emplearon características descriptivas de MCs individuales y de clúster de MCs para comparar el desempeño de tres clasificadores [13].

### Máquinas de aprendizaje (MA)

Los autores Songyang y Ling propusieron un método para la detección automática de clúster de MCs [14]. Fu, Lee y su colectivo de autores se propusieron un procedimiento de detección de MCs dividido en dos fases [15]. Las máquinas de aprendizaje han sido capaz de producir poderosos clasificadores de clúster de MCs, pero podrían correr el riesgo de

sobreajuste de los datos. Clasificadores basados en ANN [14], algoritmos genéticos evolutivos [16] y Máquinas de Soporte Vectorial [17] han demostrado tener gran precisión.

### Métodos para la detección de masas

Las masas son más difíciles de detectar que las MCs, debido a que tienden ser oscuras o similares a los tejidos de pecho normal. Varios métodos de detección de masas han sido propuestos en la literatura. Muchos de estos métodos combinan el problema de detección y clasificación de regiones sospechosas en imágenes de mamografía y podrían dividirse en las siguientes categorías: Mejoramiento de Imagen, Extracción de Características y ANN.

### Mejoramiento de imagen

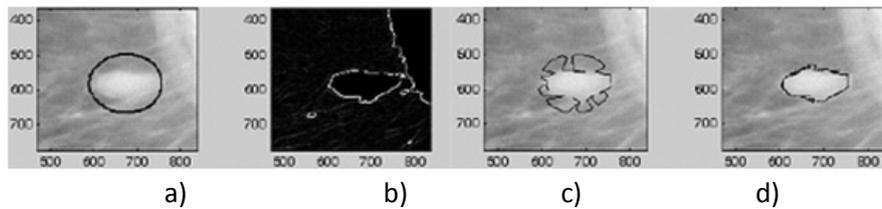
Los autores Sahba y Venetsanopoulos propusieron un operador fuzzy para el mejoramiento del contraste en imágenes de mamografías [18]. En el trabajo desarrollado por los autores Cheng y Xu, se desarrolló un método de mejoramiento del contraste basado en la lógica fuzzy para imágenes de mamografías [19]. Kom, Tiedeu y su colectivo de autores propusieron un algoritmo de detección de masa basado en un filtrado de transformación lineal para mejorar la imagen [20]. Los autores Sampat y Bovik desarrollaron una técnica para el mejoramiento de las espiculaciones. Dicha técnica empleó un filtro lineal aplicado a la transformación aleatoria de la imagen [21].

### Extracción de características

Los autores Heang-Ping y Chan propusieron un algoritmo basado en la región donde ocho características de textura fueron calculadas a partir de las matrices de dependencia de niveles de grises [22]. Sahiner, Heang-Ping y colectivo de autores emplearon una Red Neuronal de Convolución para distinguir entre la masa y el tejido normal [23]. Mudigonda, Rangayyan y colectivo de autores desarrollaron un método usando características basadas en la textura y en el gradiente para distinguir las masas benignas de los tumores malignos [24]. Wei, Sahiner, colectivo de autores, propusieron un método de preselección en dos etapas, que combina el análisis del campo del gradiente con información de los niveles de grises para identificar masas candidatas en imágenes de FFDM [25]. Bellotti, De Carlo, colectivo de autores, desarrollaron un sistema CAD para la detección de masas, para ello emplearon una ANN Feedforward [26]. En los trabajos de los autores Ayres y Rangayyan, se propuso un método para detectar y localizar distorsiones de la arquitectura mediante el análisis de la textura orientada en las mamografías en el cual se utilizaron los filtros Gabor [27]. Los autores Miller y Astley plantearon una técnica para la detección de asimetría bilateral que incluye un procedimiento semiautomático basado en la textura para la segmentación del tejido glandular y el análisis de la forma entre diferentes vistas [28].

### Redes neuronales artificiales

Ferreira, Nascimento y su colectivo de autores desarrollaron un nuevo método de segmentación de objetos en imágenes de mamografías el cual usa un modelo de contorno activo basado en una ANN Auto-Organizada y el isomorfismo espacial [29] La Figura 1 muestra la exactitud del método propuesto comparado con el algoritmo original desarrollado por Venkatesh.



**Figura 1 (a) Imagen original con lesión sospechosa, (b) Mapa de borde. (c) contorno final obtenido por el método original (d) contorno final obtenido por el método propuesto. Fuente: [29].**

López, Nova y colectivo de autores desarrollaron un sistema CAD para clasificar lesiones patológicas. El método incluye cinco etapas: selección del ROI, filtrado CLAHE, segmentación (basado en MD), extracción de características (área del objeto, intensidad, forma del objeto y elongación) y clasificación (basado en dos modelos de ANN: Feedforward Backpropagation(FFBP) y de Regresión Generalizada[30].

## MÉTODO PROPUESTO

A continuación se describe un método para la detección/clasificación del cáncer de mama (benigna o maligna) presente en imágenes de mamografías, el cual se fundamenta en la correcta combinación de un vector compuesto por características de forma y textura. También se presenta el proceso de análisis estadístico para la reducción de conjuntos de características y obtención de vectores óptimos en el proceso de clasificación.

### Descripción del Método Propuesto

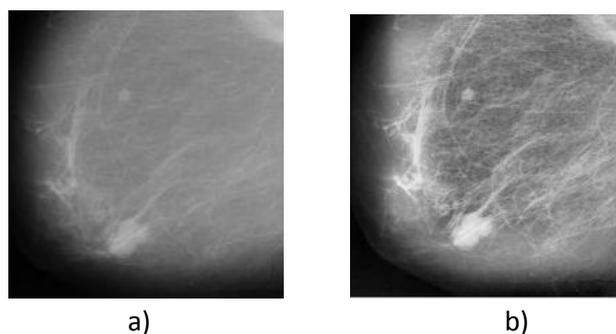
Con el objetivo de desarrollar un algoritmo tomando como base las técnicas de Procesamiento Digital de Imágenes, Reconocimiento de Patrones e Inteligencia Artificial, se realizaron los siguientes módulos:

1. Pre-procesamiento de las imágenes.
  - Mejoramiento de imagen.
  - Segmentación.
  - Extracción de Características.
2. Procesamiento estadístico.
  - Reducción del conjunto.
3. Clasificación.
  - Casos de pruebas.
  - Resultados.

## PRE-PROCESAMIENTO DE LAS IMÁGENES

### 1.1-Mejoramiento de imagen

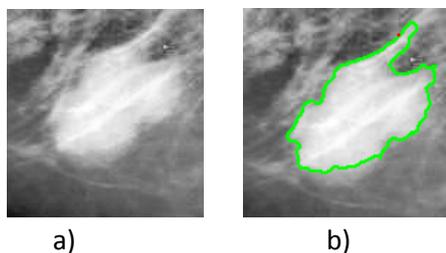
El mejoramiento de imagen se utiliza para eliminar en gran medida el ruido de las imágenes producto a su captura o formación. En esta investigación se aplica la Ecuación del Histograma de Contraste Adaptativo, la cual realiza una mejora del contraste de forma uniforme mediante la transformación de los valores de intensidad de los píxeles de las imágenes, consiguiendo de esta forma, mejorar el contorno de los objetos de interés [31] (ver Figura 2).



**Figura 2. Ecuación del histograma de contraste adaptativo a) Imagen original. b) Imagen procesada. Fuente: Elaboración propia.**

### 1.2-Segmentación

En el proceso de segmentación del objeto de interés (tumor) se utiliza una técnica conocida como “cortes inteligentes” (*live wire or intelligent scissors*). Según Liang, el *live wire* basa su funcionamiento en dos componentes esenciales: una “función de costo” local que asigna el menor costo a las características de mayor interés de los objetos (por ejemplo los bordes) y un “proceso de expansión” que genera bordes óptimos para los objetos de interés, basados en la mencionada función de costo y un pequeño conjunto de puntos semillas que son suministrados por el usuario [32] (ver Figura 3).



**Figura 3. Segmentación con el live wire a) Imagen original b) Imagen segmentada. Fuente: Elaboración propia.**

### 1.3-Extracción de Características

El proceso de extracción de características se genera a partir del objeto segmentado del cual se extraen un conjunto de treinta y dos características de forma y textura.

Las características de forma brindan información basada en la morfología del objeto, mientras que las de textura describen la topología y se basan en las matrices de coocurrencia de niveles de gris.

En este trabajo para conformar el conjunto de datos inicial se extrajeron un total de 15 características de forma y 5 de textura a partir de cada matriz de coocurrencia de niveles de gris a diferentes ángulos (0, 45, 90, 135).

## PROCESAMIENTO

### 2.1-Reducción del conjunto (vector características) mediante el procesamiento estadístico.

El objetivo de la reducción del conjunto de datos inicial es encontrar un subconjunto de características con la restricción de que logren minimizar el error de los clasificadores, dado que se trata de reducir la dimensionalidad del vector de entrada detectando y rechazando aquellas características que presentan un bajo o nulo poder discriminante. En esta investigación se utilizó el Análisis Factorial y de Correlación para encontrar grupos homogéneos de variables a partir de un conjunto numeroso de características. Estos grupos homogéneos se forman con las características que presentan un alto grado de correlación entre sí y procurando, inicialmente, que unos grupos de características sean independientes de otros. Se empleó específicamente el método de Extracción Factorial de Componentes Principales. El cual es una técnica estadística de síntesis de la información, o reducción de la dimensión (número de variables). Donde los nuevos Componentes Principales obtenidos serán una combinación lineal de las variables originales, y además serán independientes entre sí.

Reduciendo el conjunto de datos inicial y obteniendo los vectores de características más representativos, se realizó un procesamiento estadístico, mediante el antes mencionado Análisis Factorial por el método de Componentes Principales para cada una de las lesiones por separadas y en conjunto. Para esto, se llevó a cabo un análisis de la tabla de varianzas total explicada, donde se seleccionan las componentes de mayor por ciento acumulado (Componente 1 y 2), donde se determinó que la Componente 1 representa las características de forma y la Componente 2 las de textura. Una vez obtenidas las componentes antes mencionadas se procedió a generar el Gráfico de Componentes. A partir de esta información visual podemos determinar la formación de varios grupos de características y corroborar el nivel de correlación entre ellas obtenido mediante la Matriz de Correlaciones. Los altos niveles de correlación y el bajo valor de significación existente demuestran que algunos de estos rasgos no aportan suficiente información a los clasificadores o que la información es redundante y por tanto, pocas características explicarán gran parte de la variabilidad, por lo que se eliminarán todas esas que no tienen peso (bajo nivel de correlación) a la hora de conformar el vector de características final.

## ANÁLISIS Y VALIDACIÓN DEL MÉTODO PROPUESTO

Se elaboraron 7 casos de pruebas destinado al entrenamiento y prueba de un conjunto de 6 clasificadores diferentes, con el objetivo de evaluar los vectores de características propuestos y determinar su comportamiento basado en los resultados obtenidos. Cada caso de prueba contiene 2 posibles vectores de características, cada uno representa una lesión y un último caso que identifica el conjunto de todas las lesiones.

Una vez definido los casos de pruebas se llevó a cabo el proceso de entrenamiento y clasificación. Para esto se seleccionó el 40% de los vectores de características extraídos como conjunto de entrenamiento y el restante 60% como conjunto de prueba. Los resultados alcanzados para cada caso de prueba se resumen en la tabla 1.

		LDC	QDC	FFBP	KNN	SVM	BAYES
<b>Caso1</b>	A1	95%	90%	100%	95%	90%	100%
	A2	90%	90%	90%	92%	88%	94%
<b>Caso2</b>	C1	93%	85%	93%	95%	93%	97%
	C2	98%	95%	98%	95%	90%	100%
<b>Caso3</b>	MC1	95%	90%	96%	75%	60%	90%
	MC2	95%	92%	99%	94%	94%	93%
<b>Caso4</b>	DA1	97%	90%	98%	90%	90%	97%
	DA2	94%	80%	95%	85%	85%	95%
<b>Caso5</b>	ME1	90%	92%	95%	95%	88%	90%
	ME2	93%	96%	97%	96%	96%	95%
<b>Caso6</b>	OME1	97%	98%	98%	100%	98%	95%
	OME2	95%	97%	97%	98%	90%	92%
<b>Caso7</b>	CC1	30%	80%	98%	84%	90%	95%
	CC2	30%	78%	93%	81%	84%	92%

**Tabla. 1** Resumen de los resultados obtenidos para cada caso de prueba en diferentes clasificadores. Fuente: Elaboración propia.

Para el Caso de Prueba número 1. Comparando los resultados de clasificación obtenidos por los vectores de características empleados en el trabajo realizado por Miller y Astley [28], se pudo constatar que el método propuesto es más eficiente, pues alcanzó un 100% con los clasificadores *FFBP* y *BAYES*, con respecto al propuesto en la literatura (86.7%). De igual modo haciéndose un análisis de sensibilidad se puede decir que el método propuesto logró un 91%, mientras que el propuesto por [33] un 82.6%.

En el caso de prueba número 2. Analizando los resultados obtenidos por los vectores de características empleados en el método propuesto, con respecto a los desarrollados por

[34], [13] y [10] podemos decir que el método propuesto obtuvo mejor desempeño. Además, dicho resultado se puede corroborar analizando los porcentajes de clasificación obtenidos: método propuesto 98% con *FFBP* y 100% con el de BAYES, el presentado por [35] con una *ANW* (94.8%), [13] obtuvo un (81%) y [10] un 100%. Al mismo tiempo, el área bajo la curva *ROC* resultante ( $Az = 0.97$ ) es mayor que  $Az=0.5$  (50%) propuesto en la literatura como umbral de comparación de desempeño de clasificadores.

Para el caso de prueba número 3 de Masas Circunscritas, los mejores resultados de los clasificadores se obtuvieron con el vector de Masas Circunscritas2, ya que el mismo contiene características diferentes al vector Masas Circunscritas1. Con los resultados del caso de prueba se puede afirmar que las Masas Circunscritas se identifican por su morfología debido a que tienen su forma y estructura mejor definida que las demás lesiones. En cuanto a su textura, esta se caracteriza por ser homogénea y por consiguiente tener valores de Homogeneidad elevados, esto se debe a que las masas circunscritas contienen pocas variaciones de los niveles de gris, o sea se caracterizan por ser uniforme y tener altos niveles de intensidad.

A través del caso de prueba número 4, mediante los resultados obtenidos de sensibilidad por el método propuesto, se puede realizar una comparación con otros autores: método propuesto (78%) y por [21] un (80%). Por lo tanto existe una pequeña diferencia en cuanto a la sensibilidad de los métodos y entre ambos, esta puede estar dada por el conjunto de características que conforman los vectores o por el tamaño de la base de datos utilizada para las pruebas.

Analizando el caso de prueba número 5. Los resultados obtenidos se pueden corroborar verificando la sensibilidad alcanzada por el método propuesto (93%), mientras que [21] con un (91%), [36] con el (84.2%) y [37] con el (100%). Donde se puede observar que el resultado de los autores Kegelmeyer, Pruneda y colectivo presenta un mayor valor de verdaderos positivos con respecto al método propuesto. Este resultado puede estar relacionado por los parámetros que se tuvo en cuenta para el análisis de la lesión. Sin embargo el área bajo la curva *ROC* resultante del método propuesto ( $Az = 0.90$ ), supera a la obtenida por [38] de  $Az=0.70$ .

En el caso de prueba número 6, se demostró que el mejor vector en cuanto a los resultados de los clasificadores fue el vector de Otras Masas Enfermas1. Pues este posee las características que no están presentes en el vector de Otras Masas Enfermas2. Producto a la variabilidad en la forma y la textura de la lesión se producen cambios en parámetros relacionados con la variación de las intensidades y con la relación entre sus píxeles a diferentes grados.

Finalmente teniendo en cuenta los resultados alcanzados por el caso de prueba número 7 el cual engloba el conjunto completo de las lesiones, se puede concluir, que el mejor vector de características es el vector de Conjunto Completo1. Esto es debido a que este vector posee las características que constituyeron ser el conjunto de intersección entre todas las lesiones, como es el caso de : Proporción, Elongación, Energía 0°, Contraste 0°, Correlación 0°, Contraste 45° y Homogeneidad 45°, las cuales no están presentes en el vector de

Conjunto Completo2. Todo esto evidencia que existen características comunes y que poseen un alto grado de discriminación, corroborándose en el desempeño obtenido por los clasificadores evaluados. Analizando la frecuencia de aparición de variables pertenecientes a la textura en la disposición 0°, se puede decir que los mayores niveles de información pertenecientes a las diferentes lesiones patológicas están ubicadas en dicha disposición y que puede estar dado por el protocolo de adquisición de la prueba (mamografía cráneo caudal y medio lateral oblicua).

## CONCLUSIONES

Se desarrolló un algoritmo para la detección/clasificación del cáncer de mama en sus etapas iniciales a partir de imágenes de mamografías, alcanzando resultados satisfactorios.

Se demostró que con la correcta combinación de características de forma y textura, se obtienen resultados relevantes en la detección/clasificación de las diferentes lesiones patológicas presentes en las imágenes de mamografías.

Se pudo constatar que haciendo un análisis estadístico mediante el análisis factorial de componentes principales se obtiene un vector de característica reducido.

## REFERENCIAS

- [1] **ALTHUIS, M.D.**, et al., *Global trends in breast cancer incidence and mortality 1973-1997*. Int. J. Epidemiol., 2005. **34**(2): p. 405-412.
- [2] **VELOSO, V.**, *Cancro da mama mata 5 mulheres por dia em Portugal*, in *CiênciaHoje*. 2009: Lisboa, Portugal.
- [3] **TABÁR, L.**, et al., *Beyond randomized controlled trials: organized mammographic screening substantially reduces breast carcinoma mortality*. Cancer, 2001. **91**(9): p. 1724-1731.
- [4] **ISAAC LEICHTER**, et al., *Optimizing parameters for computer-aided diagnosis of microcalcifications at mammography* Academic Radiology, 2000. **7**(6): p. 406-412.
- [5] **SAMPAT, M.P., M.K. MARKEY, AND A.C. BOVIK**, *Computer-Aided Detection and Diagnosis in Mammography*, in *Handbook of Image and Video Processing (Second Edition)*, B. Al, Editor. 2005, Academic Press: Burlington. p. 1195-1217.
- [6] **NISHIKAWA, R.**, et al., *Computer-aided detection of clustered microcalcifications on digital mammograms*. Medical and Biological Engineering and Computing, 1995. **33**(2): p. 174-178.
- [7] **JEFFREY ZHI-JIE, Z., L. Liang, and X. Yinfu**. *Towards automated mammograph image analysis*. in *Information Acquisition*. 2005: IEEE International Conference.
- [8] **LINGURARU, M.G.**, et al., *A biologically inspired algorithm for microcalcification cluster detection*. Medical Image Analysis, 2006. **10**(6): p. 850-862.
- [9] **HAMID SOLTANIAN-ZADEH, FARSHID RAFIEE-RAD, AND S.P.-N. D.**, *Comparison of multiwavelet, wavelet, Haralick, and shape features for microcalcification classification in mammograms* Pattern Recognition, 2004. **37**(10): p. 1973-1986.
- [10] **LIANG, S., R.M. RANGAYAN, AND J.E.L. Desautels**, *Application of shape analysis to mammographic calcifications*. Medical Imaging, IEEE Transactions on, 1994. **13**(2): p. 263-274.
- [11] **VELDKAMP WJ, K.N.**, Otten JD, Hendriks JH, *Automated classification of clustered microcalcifications into malignant and benign types*. Med. Phys., 2000. **27**(11): p. 2600-2608.
- [12] **LEE, S.-K., ET AL.**, *Classification of clustered microcalcifications using a Shape Cognitron neural network*. Neural Netw., 2003. **16**(1): p. 121-132.
- [13] A. Papadopoulos, D.I. Fotiadis, and A. Likas, *Characterization of clustered microcalcifications in digitized mammograms using neural networks and support vector machines*. Artificial intelligence in medicine, 2005. **34**(2): p. 141-150.
- [14] **SONGYANG, Y. AND G. LING**, *A CAD system for the automatic detection of clustered microcalcifications in digitized mammogram films*. Medical Imaging, IEEE Transactions on, 2000. **19**(2): p. 115-126.
- [15] **J.C. FU**, et al., *Image segmentation feature selection and pattern classification for mammographic microcalcifications*. Computerized Medical Imaging and Graphics, 2005. **29**: p. 419-429.

- [16] **JIANG, J., B. YAO, AND A.M. WASON**, *A genetic algorithm design for microcalcification detection and classification in digital mammograms*. Computerized medical imaging and graphics : the official journal of the Computerized Medical Imaging Society, 2007. **31**(1): p. 49-61.
- [17] **SINGH, S., ET AL.** *SVM Based System for classification of Microcalcifications in Digital Mammograms*. in *Engineering in Medicine and Biology Society, 2006. EMBS '06. 28th Annual International Conference of the IEEE*. 2006.
- [18] **SAHBA, F. AND A. VENETSANOPOULOS**. *Contrast enhancement of mammography images using a fuzzy approach*. in *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*. 2008.
- [19] **CHENG, H.D. AND H. XU**, *A novel fuzzy logic approach to mammogram contrast enhancement*. Information Sciences, 2002. **148**(1): p. 167-184.
- [20] **KOM, G., A. TIEDEU, AND M. KOM**, *Automated detection of masses in mammograms by local adaptive thresholding*. Computers in Biology and Medicine, 2007. **37**(1): p. 37-48.
- [21] **SAMPAT, M.P. AND A.C. BOVIK**. *Detection of spiculated lesions in mammograms*. in *Engineering in Medicine and Biology Society, 2003. Proceedings of the 25th Annual International Conference of the IEEE*. 2003.
- [22] **HEANG-PING, C. AND ET AL.**, *Computer-aided classification of mammographic masses and normal tissue: linear discriminant analysis in texture feature space*. Physics in Medicine and Biology, 1995. **40**(5): p. 857.
- [23] **AHINER, B.**, et al., *Classification of mass and normal breast tissue: a convolution neural network classifier with spatial domain and texture images*. Medical Imaging, IEEE Transactions on, 1996. **15**(5): p. 598-610.
- [24] **MUDIGONDA, N.R., R. RANGAYYAN, AND J.E.L. DESAUTELS**, *Gradient and texture analysis for the classification of mammographic masses*. Medical Imaging, IEEE Transactions on, 2000. **19**(10): p. 1032-1043.
- [25] **WEI, J.**, et al., *Computer-aided detection of breast masses on full field digital mammograms*. Medical physics, 2005. **32**(9): p. 2827-2838.
- [26] **BELLOTTI, R.**, et al., *A completely automated CAD system for mass detection in a large mammographic database*. Medical physics, 2006. **33**(8): p. 3066-3075.
- [27] **AYRES, F.J. AND R.M.** Rangayvan, *Characterization of architectural distortion in mammograms*. Engineering in Medicine and Biology Magazine, IEEE, 2005. **24**(1): p. 59-67.
- [28] **MILLER, P. AND S.M. ASTLEY**. *Detection of breast asymmetry using anatomical features*. in *Biomedical Image Processing and Biomedical Visualization 2005*. San Jose, CA, USA.
- [29] **FERREIRA, A.A.**, et al. *Analysis of mammogram using self-organizing neural networks based on spatial isomorphism*. in *Neural Networks, 2007. IJCNN 2007. International Joint Conference on*. 2007.
- [30] **LÓPEZ, Y.**, et al., *Breast Cancer Diagnosis Based on a Suitable Combination of Deformable Models and Artificial Neural Networks Techniques*, in *Progress in*

- Pattern Recognition, Image Analysis and Applications*. 2008b, Springer Berlin / Heidelberg. p. 803-811.
- [31] **DÍAZ, S.A.O.**, *Detección Automática de Agrupamientos de Microcalcificaciones en Mamografías Digitalizadas*. 2004.
- [32] **LIANG, J., MCINERNEY, T., TERZOPOULOS, D.**, *United Snakes*. IEEE Transactions on Medical Image Analysis, 2006. **10**: p. 215-233.
- [33] **RANGAYYAN, R.M., R.J. FERRARI, AND A.F. FRERE**, *Analysis of bilateral asymmetry in mammograms using directional, morphological, and density features*. Journal of Electronic Imaging, 2007. **16**(1): p. 013003-12.
- [34] **DHAWAN, A.P., Y. CHITRE, AND C. KAISER-BONASSO**, *Analysis of mammographic microcalcifications using gray-level image structure features*. Medical Imaging, IEEE Transactions on, 1996. **15**(3): p. 246-259.
- [35] **KRAMER, D. AND F. AGHDASI**. *Texture analysis techniques for the classification of microcalcifications in digitised mammograms*. in *AFRICON, 1999 IEEE*. 1999.
- [36] **SHENG, L., C.F. BABBS, AND E.J. Delp**, *Multiresolution detection of spiculated lesions in digital mammograms*. Image Processing, IEEE Transactions on, 2001. **10**(6): p. 874-884.
- [37] **KEGELMEYER, W.P.**, et al., *Computer-aided mammographic screening for spiculated lesions*. Radiology, 1994. **191**(2): p. 331-337.
- [38] **JIANG, L., ET AL.**, *Automated Detection of Breast Mass Spiculation Levels and Evaluation of Scheme Performance*. Academic Radiology, 2008. **15**(12): p. 1534-1544.