

# DETECCIÓN AUTOMÁTICA DE LESIONES EN LA MAMA

Gloria Bueno

E.T.S.I. Industriales, Universidad de Castilla-La Mancha  
Avda. Camilo José Cela, 3. 13071 Ciudad Real. Gloria.Bueno@uclm.es

Antonio Martínez\*, Jose M<sup>a</sup> Caballero<sup>+</sup>, Pablo Cosías\*, Alberto Martín\*

\*E.T.S. Informática, UCLM. <sup>+</sup>E.T.S.I. Industriales, UCLM.

{Antonio.Malbala, Josemaria.Caballero}@uclm.es

{Pablo.Cosias, Alberto.Martin}@alu.uclm.es

Antonio Adán

E.T.S. Informática, UCLM. Antonio.Adan@uclm.es

## Resumen

*Este trabajo presenta un estudio realizado para la detección de lesiones en la mama mediante diversas técnicas de procesamiento de imágenes basado en: clusterización por lógica difusa, filtrado por  $\beta$ -splines, filtrado adaptativo y análisis en frecuencias (wavelets) según la lesión a considerar. La detección precoz es el único medio de mejorar el pronóstico del cáncer de mama y reducir así significativamente la mortalidad debida a esta enfermedad. De ahí la importancia de tener sistemas CAD que mejoren la velocidad y precisión del diagnóstico en screening de mamografías. Con este objetivo se realiza este trabajo cuyo propósito general es implementar un sistema CAD para dicho diagnóstico. Se presenta una validación cualitativa de la experimentación realizada hasta el momento con las técnicas de detección consideradas. Los resultados obtenidos son satisfactorios en la detección de lesiones tipo nódulos, micro-calcificaciones y distorsiones.*

**Palabras Clave:** Procesado de Mamografías, Wavelets, Filtrado  $\beta$ -splines, Filtrado Adaptativo, Clustering, Lógica Difusa.

## 1 INTRODUCCIÓN

Resulta vano destacar la importancia y el interés del estudio de cáncer de mama. Esta enfermedad es mítica por sus terribles consecuencias vitales y por sus repercusiones. La trascendencia de su detección es manifiesta, pues constituye la principal causa de mortalidad por cáncer entre

las mujeres. La detección precoz es la única arma contra esta enfermedad. En los últimos 10 años se han realizado numerosos ensayos clínicos para evaluar la eficacia de la detección precoz por mamografía, constatando que la detección y tratamiento de esta enfermedad permite reducir su mortalidad en un 20-30%. Cuanto antes se detecte esta enfermedad más altas son las posibilidades de curación. Si el tumor de mama no supera los 2 centímetros la supervivencia es del 80% de las mujeres afectadas, [10].

Recientemente sistemas de ayuda al diagnóstico, *Computer Aided Diagnosis*, (CAD), han recibido especial interés como sistemas de ayuda al diagnóstico en screening de mamografías. El principal objetivo es mejorar la sensibilidad del diagnóstico, ayudando a los especialistas en la detección de casos que, de otra forma podrían no detectarse. A pesar de ello la interpretación automática de lesiones en mamografías todavía es un problema difícil y sin una solución generalizada. La dificultad del problema reside, por una parte, en la complejidad de las imágenes y objetos (lesiones mamográficas) a estudiar. Los componentes perceptibles de la mama en una mamografía (grasa, fibra conjuntiva y posiblemente lesiones) hacen las imágenes complejas. Por otra parte, tanto las glándulas mamarias como las características de las lesiones mamográficas pueden variar de forma radical entre pacientes, [5, 1]. Ante estas motivaciones surge este proyecto, cuyo objetivo es la detección y caracterización para su posterior clasificación de regiones indicativas de lesiones en la mama.

En este artículo se presenta las técnicas implementadas hasta el momento para la detección de estas regiones. Entre las diversas técnicas de segmentación, basadas en métodos estadístico, [2], modelización, [16], y análisis en frecuencia, [15], que aparecen en la literatura para el procesamiento de mamografías, en concreto se han utilizado técnicas de clusterización por lógica difusa para la detección de las lesiones tipo nódulos, técnicas de filtrado por  $\beta$ -splines y adaptativo para micro-calcificaciones y análisis con *wavelets* para lesiones tipo distorsión.

Este proyecto está todavía bajo desarrollo y su objetivo final es implementar un clasificador para discernir la benignidad o malignidad de las zonas detectadas. De ahí que actualmente también se está trabajando en la caracterización de estas regiones mediante distintos descriptores de textura, forma y contraste para su posterior clasificación.

A continuación se describen las técnicas de segmentación en la sección 2. Sección 3 presenta los resultados experimentales realizados con imágenes de mamografías correspondientes a distintos tipos de tejido mamario (graso glandular, graso y denso) y con distintos tipos de lesiones (nodulares, micro-calcificaciones y distorsiones) tanto benignas como malignas. Se presentan también las delineaciones manuales de estas imágenes; delineaciones realizadas por un experto oncólogo en patología mamaria. Finalmente la sección 4 expone las conclusiones de este trabajo.

## 2 DETECCIÓN

### 2.1 LESIONES NÓDULOS

Los nódulos son concentraciones de masa que se muestran en la mamografía como formas relativamente bien definidas. El método utilizado para la detección de nódulos está basado en la teoría de agrupación o *clustering* por lógica difusa o *Fuzzy Logic*, más concretamente en el algoritmo de *Fuzzy C - Means*, (FCM), [3].

#### 2.1.1 Fuzzy C-Means Clustering

La teoría de lógica difusa proporciona una herramienta matemática eficiente para analizar información imprecisa e indefinida, como puede ser el caso de la información proveniente de imágenes médicas con ruido, bajo contraste y regiones de interés mal definidas.

El algoritmo de clustering Fuzzy C-means (FCM), es utilizado para realizar una clasificación preliminar de tejidos. El algoritmo agrupa píxeles pertenecientes a la imagen,  $I(x, y) = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ , en un número  $c$  de clases previamente establecido y caracterizadas por su centroide. La agrupación se hace mediante el cálculo de una medida de pertenencia llamada pertenencia *fuzzy*, en cada píxel y para cada clase  $c$ , [9]. El valor de la función de pertenencia *fuzzy* está restringido entre 0 y 1, y refleja el grado de similitud entre el valor del píxel en esa localización y el centroide de su clase. Así, un valor de pertenencia *fuzzy* elevado cercano a 1 significa que el valor del píxel en esa localización está cercano al centroide para esa clase particular. El algoritmo *FCM* está formulado como la minimización de las siguientes funciones de errores cuadráticos con respecto a las funciones de pertenencia,  $U$ , y el conjunto de centroides,  $\{V\} = \{v_1, v_2, \dots, v_n\}$ :

$$J(U, V : X) = \sum_{i=1}^c \sum_{k=1}^n (u_{ik})^m \|\mathbf{x}_k - v_i\| \quad (1)$$

donde  $u_{ik} = u_i(\mathbf{x}_k)$  es la pertenencia de  $x_k$  en la clase  $i$  y  $m \geq 1$  es el peso de cada pertenencia *fuzzy*. Calculando las primeras derivadas de 1 con respecto a  $u_{ik}$  y  $v_k$  e igualando a 0 se cumplen las condiciones necesarias para minimizar 1. Los valores de  $u_{ik}$  y de  $v_k$  quedan entonces definidos como:

$$u_{ik} = \left[ \sum_{j=1}^c \left( \frac{\|\mathbf{x}_k - v_i\|}{\|\mathbf{x}_k - v_j\|} \right)^{\frac{2}{m-1}} \right]^{-1} \quad (2)$$

y

$$v_i = \frac{\sum_{k=1}^n (u_{ik})^m x_k}{\sum_{k=1}^n (u_{ik})^m} \quad \forall i, k \quad (3)$$

Iterando con estas condiciones se llega a minimizar la función objetivo, (1). El criterio de parada está determinado para cada iteración por  $E_i < \varepsilon$  donde:

$$E_i = \sum_{i=1}^c \|v_{i,t+1} - v_{i,t}\| \quad \forall t \quad (4)$$

Una vez que el método converge, se obtiene una matriz que muestra para cada píxel de la imagen su pertenencia en todas las clases  $c$ . Finalmente, la máxima pertenencia *maximum membership*,  $\max(u_{ik})$ , es asignada para cada cluster  $\mathbf{x}_k$  obteniéndose la imagen segmentada por FCM. El resultado del algoritmo de *FCM* puede variar en función del valor del cluster seleccionado

y la posición de los centroides  $V$ . Una selección adecuada ayudará a mejorar la precisión y convergencia del algoritmo. En este trabajo se ha hecho un análisis del histograma de las mamografías de forma que el conjunto inicial de clusters y centroides está asociado a los máximos del histograma. Figuras 2 y 3 muestran los resultados del algoritmo de *FCM* aplicado a imágenes de mamografías con tejido graso y graso-glandular, que contienen lesiones tipo nódulos benignas y malignas.

## 2.2 LESIONES CALCIFICACIÓN

Las calcificaciones se muestran en la imagen como puntos de alta intensidad y marcado contraste. Para localizar las calcificaciones se han estudiado dos filtros, filtrado por  $\beta$ -splines y filtrado adaptativo. Estos filtros tienen como objetivo realzar las posibles lesiones en los distintos tipos de tejido mamario.

### 2.2.1 Contraste - $\beta$ -splines

El uso de *splines* se ha generalizado a diversas aplicaciones en tratamiento de señal y procesamiento de imágenes, entre las que destacan: re-escalado, visualización, transformaciones geométricas, registro de imágenes y modelización, [13, 14, 12].

En este trabajo se presenta brevemente el procesado con  $\beta$ -splines que se ha realizado a las imágenes de mamografías y los resultados preliminares obtenidos. El modelo  $\beta$ -spline aplicado a la imagen es una *spline* cúbica con un grado de expansión de 1. El filtro  $\beta$ -spline,  $(b_1^3)^{-1}$  se ha implementado usando un filtro causal, (*fc*), y anticausal, (*fac*), recursivamente. El filtro es de la forma:

$$(b_1^3)^{-1}(k) \leftrightarrow = \frac{6}{z + 4 + z^{-1}} \quad (5)$$

en función del filtro causal y anticausal quedaría  $(B_1^3)^{-1}(z) = 6 * (fc) * (fac)$ , donde:

$$fc = \frac{1}{1 - z_1 z^{-1}} \quad , \quad fac = \frac{-z_1}{1 - z_1 z} \quad (6)$$

Una vez transformada la imagen con el modelo  $\beta$ -spline cúbico se aplica el operador derivada de primer orden,  $(1 - z^{-1})$ , en ambas direcciones, tanto en el eje- $X$  como en el eje- $Y$ , calculándose posteriormente el módulo del gradiente. Finalmente, se re-escala la imagen linealmente para su visualización. Se debe destacar que este

procesado se aplica sólo a la región mamaria extraída previamente de la imagen total.

El resultado de este proceso es una imagen con los puntos y regiones de cambio máximo resaltados. Figuras 4 y 4.c-d muestran los resultados obtenidos al aplicar este filtro.

### 2.2.2 Filtrado Adaptativo 2D

El tratamiento de imágenes basados en algoritmos recursivos que requieren un coste computacional elevado ha experimentado avances en las últimas décadas, consecuencia del incremento en la potencia de cálculo de los procesadores actuales. En este sentido, Serrano *et al*, [11] ha utilizado un filtro predictor lineal 2D, como herramienta auxiliar para la generación de semillas en la segmentación por crecimiento de regiones. Melany *et al*, [8], ha desarrollado una versión del algoritmo 2D de *Least Squares* para control de calidad. Basado en estos métodos, y en los trabajos de Liu X. *et al*, [6] y [4], en este proyecto se ha implementado una versión modificada del algoritmo *Fast Recursive Least Squares Lattice* para la detección de lesiones (micro-calcificaciones) en mamografías.

La estructura 2D Lattice [4] está formada por multientradas y multisalidas unidas y definidas en función de una serie de coeficientes de ajuste. La salida a analizar está formada por los errores de predicción hacia detrás (estimación del valor de la muestra pasada a partir de las siguientes,  $e_M^b(n)$ ) y hacia delante (estimación de la siguiente muestra a a partir de las anteriores,  $e_M^f(n)$ ).

El algoritmo lo constituye un predictor-estimador 2D que aporta una solución exacta para la estimación de la señal de entrada siguiendo el criterio de minimización del error de la solución por mínimos cuadrados. Para ello utiliza como entrada una región de soporte  $R$  de tamaño variable  $(M+1, N+1)$ , como se muestra en la figura 1. En su primera iteración el algoritmo utiliza los  $M$  píxeles situados en la vertical al píxel en proceso. En  $N$  sucesivas iteraciones utilizará los valores de predicción utilizados en los píxeles anteriores. A diferencia del algoritmo original, se ha optado por una máscara simétrica respecto a la fila del píxel procesado a la entrada. De esta forma se consigue hacer el procesado mucho más sensible a las variaciones direccionales de los píxeles del contorno.

Analíticamente se puede expresar el valor estimado como:




Figure 1: Región soporte del filtro

$$\hat{x}(n_1, n_2) = \sum_{i,j \in R} a_{i,j} x(n_1 - i, n_2 - j) \quad (7)$$

Siendo  $(n_1, n_2)$ , los índices de las filas y las columnas, respectivamente, de la imagen y  $a_{i,j}$  es el modelo a estimar. La función de coste,  $\xi$  a minimizar es:

$$\text{Min}[\xi_m(n)] = \text{Min}\left[\sum_{k=0}^n \lambda_{n-k} [e_m(k)]^2\right] \quad (8)$$

donde:  $k = (j * \text{dim}_x + i)$ ,  $e_m(k) = x(k) - \hat{x}(k)$  y  $\lambda$  es el factor de olvido que se representa utilizando un índice de barrido lineal  $n$  del tipo:

$$n = n_2 * \text{dim}_x + n_1 \quad (9)$$

Donde  $\text{dim}_x$  es la dimensión de la imagen en el eje de abscisas. Dicha función de coste puede ser re-escrita recursivamente:

$$\xi_m(n) = \lambda \xi_m(n-1) + [e_m(n)]^2 \quad (10)$$

Así se minimiza la suma del error cuadrático medio que aporta la solución *LS*, y con un elemento dependiente de las estimaciones anteriores del filtro. La constante  $\lambda$  permite modificar la influencia de los valores estimados por muestras pasadas en la función del error. En general esta constante, cuyo valor debe ser próximo a la unidad, incrementa la velocidad de convergencia del filtro con la desventaja de que puede producir inestabilidad. Aquí se ha considerado igual a la unidad.

Se puede interpretar el error de predicción desde una perspectiva geométrica como la proyección de la señal de entrada sobre el espacio generado por la combinación lineal de las muestras que forman la región soporte del filtro. De esta forma se definiría una componente angular,  $\theta$ , como el ángulo formado entre la señal de entrada y su proyección sobre el espacio de predicción. Valores cercanos a cero indicarán una buena

aproximación.

Como parámetro de salida del algoritmo se obtiene  $\theta$ , cuyas características de sensibilidad ante perturbaciones de la señal de entrada, la hacen muy útil para la determinación de bordes o irregularidades, es decir contornos de las *ROI*.  $\theta$ , que viene dada en función de la tasa angular,  $\gamma_m(n)$ , de la forma:  $\gamma_m(n) = \cos^2(\theta)$ ,  $\gamma$  presenta valores próximos a la unidad cuando el error de predicción es pequeño y reaccionará con caídas bruscas cuando procese discontinuidades.

La salida del algoritmo, enfocado a la extracción de lesiones, representa la proyección 2D del relieve topográfico cuya altitud es la intensidad de la tasa angular. Se observa la sensibilidad de la tasa angular para delimitar los bordes de las zonas de interés. Así para realizar la extracción de lesiones, es decir extraer aquellos píxeles correspondientes a variaciones de la tasa angular,  $\gamma$ , se ha realizado una selección mediante umbral. Dado que  $\gamma$  es un parámetro variable, el umbral de decisión también lo es.

Los pasos del proceso son:

1. Para cada píxel  $p(n_1, n_2)$ , se calcula la diferencia entre  $\gamma(p)$  y la de sus vecinos:

$$\Delta_{n_1, n_2} = \max[\gamma_m(n_1, n_2) - \gamma_m(n_1 - i, n_2 - j)] \quad (11)$$

2. Si se cumple que:

$$\Delta_{n_1, n_2} \geq \text{mean}\left[\Delta_{n_1 - \frac{\text{dim}_x}{2}, n_2} - \Delta_{n_1 + \frac{\text{dim}_x}{2}, n_2}\right] \quad (12)$$

es decir, para un píxel perteneciente a una determinada fila de la imagen, si se supera el valor medio de dicha diferencia en la fila en cuestión, escogemos los índices del píxel como candidatos.

3. Crecimiento de la *ROI* o agrupación de los candidatos de forma que se eliminen aquellas regiones de área menor o igual a 5 píxeles. A continuación a efectos de visualización se rellenan las *ROI*.

Figuras 5.e-f ilustran los resultados de este filtro para dos imágenes de mamografías.

## 2.3 LESIONES DISTORSIONES

Las distorsiones podrían definirse como tejidos que convergen hacia un mismo punto. Estas lesiones son normalmente las más difíciles de localizar, más aún si se dan en tejido denso y graso. Una de las técnicas de procesamiento de señal más útiles para el análisis en frecuencias es la transformada *wavelet*. Existen numerosos artículos y documentos que describen la teoría de *wavelets* y sus aplicaciones. No es el propósito de este trabajo hacer una descripción detallada de ésta, no obstante, se describe brevemente el concepto base de la transformada *wavelet* y el estudio preliminar realizado hasta el momento en este proyecto para el análisis de mamografías.

### 2.3.1 Wavelets

La transformada de *wavelet* descompone señales en funciones base que son dilataciones y traslaciones de un prototipo simple de la función *wavelet*, [7]. Así una señal  $f(t)$  se puede representar en el dominio de *wavelet* de la siguiente forma:

$$f(t) = \sum_{m=0}^{\infty} \sum_{n=0}^{\infty} (c_n^m) \phi_{m,n}(t) \quad (13)$$

Donde  $\phi_{m,n}(t) = 2^{-m/2} \phi(2^m t - n)$ , son obtenidas mediante traslaciones y dilataciones de la función *wavelet*  $\phi(t)$ . Los coeficientes de la transformada *wavelet* discreta,  $(c_n^m)$ , pueden ser calculados por los productos internos  $\langle \phi_{m,n}(t), f(t) \rangle$ .

Actualmente, la transformada *wavelet* discreta corresponde a expresiones de aproximación de multi-resolución. Este método permite el análisis de la señal en múltiples bandas de frecuencia o en muchas escalas. En la práctica, el análisis de multi-resolución se ha llevado a cabo utilizando dos bancos de filtros de espejo de cuadratura compuestos por un paso-bajo, ( $G$ ), y un paso-alto ( $H$ ). Cada banco de filtros es entonces muestreado a la mitad de la frecuencia anterior, ( $1/2$  *down sampling*). Mediante la repetición de este procedimiento, es posible obtener la transformada *wavelet* de cualquier orden. El procedimiento de *down sampling* conserva constante el parámetro de escala ( $1/2$ ) para todas las transformadas *wavelet* sucesivas. De acuerdo con este procedimiento, la imagen original puede ser transformada en 4 sub-imágenes conteniendo bajas o/y altas frecuencias en las direcciones horizontal o/y vertical. Existen varias funciones base que son utilizadas para la descomposición de *wavelets*. En este estudio se han utilizado 2

tipos de funciones básicas para la descomposición *wavelet*: función Haar, función Dabauchies de 4 y 20 coeficientes.

Figura 6 y 7 muestran los resultados del análisis por *wavelets* realizado a las imágenes de mamografías.

## 3 RESULTADOS

Estas técnicas han sido probadas en varias imágenes de mamografías de distintos tipos de tejidos (graso, graso-glandular, denso-glandular) y de lesiones (nódulos, micro-calcificaciones y distorsiones) con diferente severidad (maligna o benigna). Los resultados se están ilustrados en las figuras 2-7.

### 3.1 NÓDULOS

Las figuras 2 y 3 presentan la segmentación de masas circunscritas o nódulos bien definidos en tejidos graso y graso-glandular, respectivamente, mediante el algoritmo de *Fuzzy C - Means*. Las figuras 2.a y 3.a ilustran la imagen original con la lesión indicada manualmente por expertos clínicos. Y las figuras 2.b y 3.b muestran la segmentación automática *FCM* con  $c = 5$  *clusters*, con los contornos de las regiones segmentadas.




Figure 2: Localización de Nódulos. (a) Original. (b) Segmentación por *FCM*. Lesión Benigna.

### 3.2 MICRO-CALCIFICACIONES

Las figuras 4 y 5 presentan la detección de calcificaciones en tejidos denso (Figura-4), graso-glandular (Figura-4.a) y graso (Figura-5.b). Los algoritmos utilizados son  $\beta$ -splines, (Figura-4) y




Figure 3: Localización de Nódulos. (a) Original. (b) Segmentación por *FCM*. Lesión Maligna.

(Figuras-5.c-d) y filtrado adaptativo, (Figuras-5.e-f). Se *Fuzzy C – Means*. Las figuras 4.a y 5.b ilustran la imagen original con la delineación manual realizada por expertos clínicos.






Figure 4: Localización de Micro-calcificaciones. (a) Original. (b) Segmentación por  $\beta$ -Splines. Lesión maligna.


Actualmente se está realizando una comparativa cuantitativa de ambos filtros, filtro por  $\beta$ -splines y filtro adaptativo. No obstante, de la experimentación realizada (cualitativamente) se puede concluir que el filtro por  $\beta$ -splines funciona mejor en la detección de microcalcificaciones en mamografías con tejido denso. Así se puede ver como en la figura 5.f los resultados del filtro adaptativo son satisfactorios mientras que en la mamografía de la figura 5.e el filtro no ha detectado las lesiones.



(a) (b)



(c) (d)



(e) (f)

Figure 5: Localización de Micro-calcificaciones. (a-b) Original. (c-d) Segmentación por  $\beta$ -Splines. (e-f) Segmentación por Filtrado Adaptativo (FRLS). (a) Lesión Maligna, (b) Lesión Benigna.

### 3.3 DISTORSIONES

Las figuras 6 y 7 presentan la segmentación de distorsiones en tejidos graso y denso-glandular, respectivamente. De forma similar a las ilustraciones previas, las figuras 6.a, 7.a y 7.b ilustran las imágenes de mamografías originales con la delineación manual realizada por expertos clínicos. La figura 6.b muestra la detección de la lesión por *wavelets* (Dabauchies 20) con eliminación de bandas bajas a un nivel de resolución de 4.




Figure 6: Localización de Distorsiones. (a) Original. (b) Análisis por *wavelets*. Lesión Maligna.

La figura 7.b muestra la detección de la lesión por *wavelets* (Haar) con eliminación de bandas altas a un nivel de resolución de 4.




Figure 7: Localización de Distorsiones. (a) Original. (b) Análisis por *wavelets*. Lesión Maligna.

## 4 CONCLUSIÓN

En este trabajo se han presentado los resultados preliminares obtenidos para el análisis de imágenes de mamografías orientado a la detección automática de diferentes lesiones en la mama. Los métodos considerados son: clusterización por lógica difusa, algoritmo de *Fuzzy C - Means*, (*FCM*), técnicas de contraste por filtrado mediante  $\beta$ -*splines* y filtrado adaptativo (*Fast Recursive Least Squares Lattice*).

El análisis realizado concluye que las diferentes técnicas son indicadas para distintos tipos de lesiones, demostrando dar resultados cualitativamente satisfactorios. Así para lesiones tipo nódulos el *FCM* es el algoritmo más indicado. En general el algoritmo predictivo 2D muestra capacidad para la detección de algunas zonas de interés, particularmente micro-calcificaciones. No obstante, el filtro mediante  $\beta$ -*Splines* resulta ser el más satisfactorio para analizar calcificaciones en todo tipo de tejido mamario. Finalmente, se ha realizado un análisis por *wavelets* para la detección de lesiones tipo distorsión. El análisis por *wavelets* muestra ser el más indicado para estas lesiones en todo tipo de tejido mamario.

Entre las futuras líneas de investigación dentro de este proyecto está el realizar un análisis más amplio de estas técnicas, con un mayor número de imágenes representativas de diferentes casos de lesiones. Estas técnicas se validarán cuantitativamente mediante métodos estadísticos y *ROC* análisis. Cabe mencionar que paralelamente a las técnicas de segmentación se están implementando diversos descriptores de textura, forma y contraste de las *ROI* que servirán para la implementación de un clasificador que ayude a discernir la benignidad o malignidad de las zonas detectadas.

### Agradecimientos

Este trabajo ha sido financiado gracias a la Junta de Comunidades de Castilla-La Mancha, proyecto JCMM/PBI-03-017, y al proyecto INBIOMED, FIS-ISCIH-G03/160.

## Referencias

- [1] L. Blot and R. Zwigelaar. Background texture extraction for classification of mammographic parenchymal patterns. In *International Conference on Medical Image Understanding and Analysis*, pages 145–148, 2001.

- [2] J. Byng, N. Boyd, and E. Fishell. The quantitative analysis of mammographic densities. *Phys. Medical Biology*, 37:1629–1638, 1994.
- [3] H. Cheng, Y. Man Lui, and R. I. Freimanis. A novel approach to micro calcification detection using fuzzy logic technique. *IEEE Trans. on Medical Imaging*, 17(3):442–450, June 1998.
- [4] S. Haykin. *Adaptive Filter Theory*. Prentice Hall International Editions, Upper Saddle River, NJ, 3rd edition edition, 1996.
- [5] M. Heath, K.W. Boyer, and D. Kopans. *Current Statuts of the Digital Database for Screening Mammography*, chapter In Digital Mammograph, pages 457–460. Kluwer Academic Publishers, 1998.
- [6] X. Liu and M. Najim. A two-dimensional fast recursive least squares algorithm. *Transactions on Signal Processing*, 44(10):2557–2567, October 1996.
- [7] S. Mallat and S. Zhong. Characterization of signals from multiscale edges. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 14(7):710–732, July 1992.
- [8] R. Meylani, A. Ertüzün, and A. Erçil. Texture defect detection using the adaptive two-dimensional lattice filter. In *IEEE Int. Conf. On Image Proc (ICIP'96)*,, pages 165–168, Lausanne, Switzerland, September 1996.
- [9] N. Mohamed and M. N. Ahmed. A modified fuzzy c-means algorithm for bias field estimation and segmentation of MRI data. *IEEE Transactions On Medical Imaging*, 21(3):193–200, March 2002.
- [10] P. Plans, L. Casademont, and L. Salleras. Cost-effectiveness of breast cancer screening in spain. *Int. J. Tech As Health Care*, 12:32–36, 1995.
- [11] C. Serrano, J. Diaz-Trujillo, B. Acha, and R. M. Rangayyan. Use of 2d linear prediction error to detect microcalcifications in mammograms. In *2º Congreso Latinoamericano de Ingenieria Biomédica*, May 2001.
- [12] M. Unser. Splines. a perfect fit for signal and image processing. *IEEE Signal Processing Magazine*, pages 22–38, November 1999.
- [13] M. Unser, A. Aldroubi, and M. Eden. B-spline signal processing: Part i-theory. *IEEE Trans. on Signal Processing*, 41(2):821–832, February 1993.
- [14] M. Unser, A. Aldroubi, and M. Eden. B-spline signal processing: Part II-efficient design and applications. *IEEE Trans. on Signal Processing*, 41(2):834–848, February 1993.
- [15] R. Zwiggelaar and C. Boggis. Classification of linear structures in mammographic images. In *International Conference on Medical Image Understanding and Analysis*, 2001.
- [16] R. Zwiggelaar, TC. Parr, and J.E Schumm. Model -based detection of speculated lesions in mammograms. *Medical Image Analysis*, 31:39–62, 1999.