

Estudio de Estabilidad de Técnicas de Filtrado en Imágenes de la Base de Datos mini-MIAS

Estíbaliz Parceró, Vicente Vidal, Gumersindo Verdú, Patricia Mayo*

Abstract— El estudio de técnicas de filtrado aplicado a imágenes médicas es de especial relevancia ya que puede ser determinante frente a un diagnóstico preciso. Este trabajo tiene como objetivo estudiar la estabilidad del filtro Fuzzy Peer Group Averaging cuando se aplica a imágenes mamográficas de distinta naturaleza en relación al tipo de tejido, anormalidad encontrada y diagnóstico. Los resultados muestran que el filtro resulta eficaz ya que obtiene un valor de PSNR de 27 comparando la imagen filtrada con la original, y un valor de 17 al comparar la imagen filtrada con la contaminada con ruido. También muestran que el filtro se comporta adecuadamente sean cuales sean las características de la imagen.

I. INTRODUCCIÓN

Durante los últimos años se han realizado una gran cantidad de estudios a fin de establecer filtros de calidad que reconstruyan imágenes con todo tipo de ruido (impulsivo, gaussiano o *speckle*) [1-11]. Esto es especialmente importante en el área de la imagen médica, donde un diagnóstico puede depender de la calidad de dicha imagen. En un estudio paralelo se ha comprobado la eficacia de filtros *fuzzy* [12-13] en una imagen mamográfica de la base de datos mini-MIAS[14].

Ahora bien, se desconoce si existe una correlación entre el tipo de tejido presente en la mama, o su diagnóstico y la eficacia del filtro aplicado, que en nuestro caso se trata del filtro Fuzzy Peer Group Averaging [12].

El objetivo del presente estudio es establecer si existe o no dicha relación, y si es así, cuantificarla. Para ello, se realizará una reconstrucción de cada una de las imágenes de la base de datos a la que habremos introducido una combinación de ruido impulsivo y gaussiano. Para cuantificar la eficacia de la reconstrucción se utilizará como medida de calidad el valor de PSNR (*Peak Signal to Noise Ratio*) para cada una de las reconstrucciones y se compararán los resultados obtenidos.

En la sección II se explica el filtro utilizado y la base de datos analizada. Los resultados del experimento realizado se presentan en la sección III y, por último, las conclusiones en la sección IV.

*Estíbaliz Parceró, Instituto de Seguridad Industrial, Radiofísica y Medioambiental, Universitat Politècnica de València, Valencia, España (e-mail: esparig@upvnet.upv.es).

Vicente Vidal, Departamento de Sistemas Informáticos y Computación, Universitat Politècnica de València, Valencia, España (e-mail: vvidal@dsic.upv.es).

Gumersindo Verdú, Departamento de Ingeniería Química y Nuclear, Universitat Politècnica de València, Valencia, España (e-mail: gverdu@iqn.upv.es).

Patricia Mayo, Titania (Grupo Dominguis), Valencia, Spain (e-mail: p.mayo@titaniast.com)

II. MATERIALES Y MÉTODOS

A. Filtro *Fuzzy Peer Group Averaging* (FPGA)

Este filtro se ejecuta en dos fases, (i) detección y reducción de ruido impulsivo, y (ii) suavizado de ruido gaussiano. En ambas fases se utiliza el *fuzzy peer group* de un pixel central x_i en una ventana W de dimensiones $n \times n$ [12] y se usa una métrica *fuzzy*.

La definición del *fuzzy peer group* se basa en la ordenación de los pixeles vecinos al pixel central x_o según su similitud.

Siendo ρ una medida de similitud entre dos vectores de la imagen los vectores $x_i \in W$ se ordenan en orden decreciente según su similitud al pixel central x_o , obteniendo el conjunto $W^1 = \{x_{(0)}, x_{(1)}, \dots, x_{(n^2-1)}\}$ de manera que $\rho(x_o, x_{(0)}) \geq \rho(x_o, x_{(1)}) \geq \dots \geq \rho(x_o, x_{(n^2-1)})$, donde $x_o = x_{(0)}$. El *peer group* $P_m^{x_o}$ de $m + 1$ miembros asociado con el pixel x_o es el conjunto:

$$P_m^{x_o} = \{x_{(0)}, x_{(1)}, \dots, x_{(m)}\} \quad (5)$$

En [8], se propone el método que determina el mejor número \hat{m} de miembros de un *peer group*. El *fuzzy peer group* de un pixel central x_o en la ventana W se define como el conjunto *fuzzy* $FP_m^{x_o}$ definido en el conjunto $\{x_{(0)}, x_{(1)}, \dots, x_{(\hat{m})}\}$ y dado por la función de pertenencia $FP_m^{x_o} = \rho(x_o, x_{(i)})$. Entonces el mejor número de miembros \hat{m} de $P_m^{x_o}$ se define como el valor de $m \in N_W = \{1, 2, \dots, n^2 - 1\}$ que maximiza la certeza de la siguiente regla *fuzzy*.

Regla Fuzzy 1: Determina la certeza de que m sea el mejor número de miembros para $P_m^{x_o}$

SI " x_m es similar a x_o " y la similitud acumulada para $x_{(m)}$ es grande ENTONCES "la certeza de que m sea el mejor número de miembros es alta".

$C_{FRI}(m)$ denota la certeza de la Regla Fuzzy 1 para m . Luego, $C_{FRI}(m)$ se calcula para cada $m \in N_W$ y el valor que maximiza la certeza se selecciona como el mayor número \hat{m} de miembros de $P_m^{x_o}$, es decir, $\hat{m} = \operatorname{argmax}_{m \in N_W} C_{FRI}(m)$.

La certeza de " x_m es similar a x_o " la proporciona la función de pertenencia C^{x_o} determinada por la medida de similitud

$$C^{x_o}(x_{(i)}) = \rho(x_o, x_{(i)}), i = 0, 1, \dots, n^2 - 1 \quad (6)$$

La similitud acumulada para x_m denominada $A^{x_0}(x_{(m)})$ se define

$$A^{x_0}(x_{(i)}) = \sum_{k=0}^{i} \rho(x_0, x_{(k)}), i = 0, 1, \dots, n^2 - 1 \quad (7)$$

Por lo tanto, la certeza de " $A^{x_0}(x_{(m)})$ es grande" se define por la función de pertenencia L^{x_0} expresada

$$L^{x_0}(x_{(i)}) = \frac{(A^{x_0}(x_{(i)}) - 1)(A^{x_0}(x_{(i)}) - 2n^2 + 1)}{(n^2 - 1)^2}, \quad (8)$$

$i = \{0, 1, \dots, n^2 - 1\}$

Y la función para calcular C_{FR1} es

$$C_{FR1}(m) = C^{x_0}(x_{(m)}) L^{x_0}(x_{(m)}).$$

La función *fuzzy* de similitud, ρ , utilizada es

$$\rho(x_i, x_j) = e^{-\frac{\|x_i - x_j\|}{F_\sigma}}, i, j = 0, 1, \dots, n^2 - 1 \quad (9)$$

donde $\|\cdot\|$ denota la norma euclídea y F_σ es un parámetro de entrada con un valor en el intervalo [0, 1] que se debe acomodar a las características de la imagen tratada [15]. La función ρ toma valores en el intervalo [0, 1] y satisface $\rho(x_0, x_i) = 1$ si y sólo si $x_0 = x_i$.

Una regla distinta es utilizada para detectar ruido impulsivo.

Regla Fuzzy 2: Determina la certeza de que el pixel x_0 esté libre de ruido impulsivo

SI la "similitud acumulada $A^{x_0}(x_{(\hat{m})})$ es grande" y " $x_{(\hat{m})}$ es similar a x_0 " ENTONCES " x_0 está libre de ruido impulsivo".

La certeza de la Regla *Fuzzy 2*, denominada C_{FR2} , la certeza de " $A^{x_0}(x_{(\hat{m})})$ es grande" viene determinada por L^{x_0} , (definida en (8)) y la certeza de " $x_{(\hat{m})}$ es similar a x_0 " es dada por C^{x_0} mediante (6).

Finalmente $C_{FR2}(x_0) = C^{x_0}(x_{(\hat{m})}) L^{x_0}(x_{(\hat{m})})$. Esta certeza ya ha sido calculada ya que $C_{FR2}(x_0) = C_{FR1}(\hat{m})$. Si la certeza de la Regla *Fuzzy 2*, C_{FR2} satisface

$$C_{FR2}(x_0) \geq F_t, \quad (10)$$

Entonces x_0 está libre de ruido impulsivo, si no x_0 contiene ruido y se reemplaza con el valor VMF_{out} [16]. F_t es el segundo parámetro de entrada discutido en [15].

B. Base de datos miniMIAS

La base de datos mini-MIAS consiste en una colección normalizada de 322 imágenes de mamografías (en blanco y negro), 161 derechas y 161 izquierdas.

Cada una de las imágenes está clasificada según el tipo de tejido dominante (graso, graso-glandular o glandular denso) y el diagnóstico: a) calcificación, b) masa bien definida o circunscrita, c) masa espigada, d) otras, masas mal definidas, e) distorsión estructural, f) asimetría, o g) normal.

III. EXPERIMENTO Y RESULTADOS

Nuestro experimento consiste en el uso del filtro indicado sobre una base de datos de imágenes mamográficas denominada mini-MIAS. Como se ha indicado anteriormente, esta base de datos está compuesta por 322 mamografías correspondientes a 161 pacientes. Cada una de estas imágenes está clasificada según el tipo de tejido de la mama, el tipo de anomalía encontrada si existe y en el caso de que se haya encontrado una masa, si es benigna o maligna.

El objetivo del trabajo es establecer si existe o no correlación entre la eficacia del filtro y el diagnóstico asociado a la imagen filtrada. La eficacia del filtro se establecerá mediante la medida PSNR, que será mejor cuanto mayor sea.

Para este estudio se ha contado con todas las imágenes de la base de datos. Estas imágenes han sido recortadas (para minimizar los cálculos al área relevante) y corrompidas con ruido (impulsivo=0.10 y gaussiano=0.01). Para ello se ha creado una función que genera una colección de imágenes que consistirá en 322 pares de imágenes originales e imágenes contaminadas.

Una vez obtenida la colección se aplica el filtro sobre las imágenes contaminadas obteniendo una imagen filtrada (figura 1) que se puede comparar con la original a fin de obtener nuestra medida de calidad (PSNR).

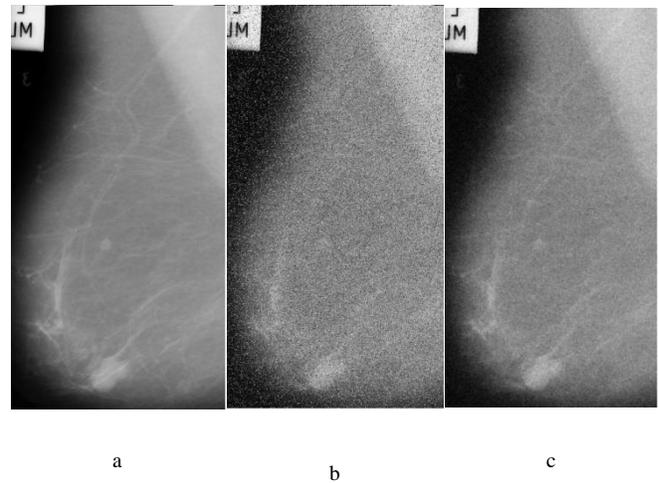


Figura 1 a) Imagen original, b) Imagen contaminada, c) Imagen filtrada

Como salida de la función de filtrado obtenemos entre otras medidas el PSNR, que servirá en nuestra evaluación para comparar la eficacia del filtro en cada una de las imágenes.

Por otra parte se realiza una carga de los datos de clasificación de las mamografías en una matriz numérica que indicará si posee o no la característica de entre las explicadas en la sección II.

Una vez obtenemos todos los datos, tanto los de eficacia del filtrado (valores PSNR por cada par original-filtrada), como los datos de clasificación de las mamografías, procedemos al análisis de éstos. Para ello mostraremos histogramas de frecuencia para valores de PSNR en función del tipo de tejido (figura 2), en función de la masa (existente o no; figura 3) y en función del diagnóstico (maligno o benigno; figura 4).

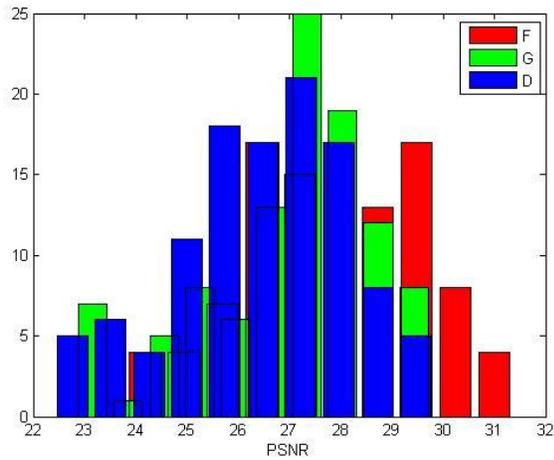


Figura 2. Histograma de los valores PSNR entre imagen original y filtrada para cada tipo de tejido: F (graso), G (graso-glandular), D (glandular-denso)

Tal y como se observa en la figura 2 los valores de PSNR siguen una distribución aproximadamente normal, siendo los valores para las imágenes de tejido graso ligeramente superiores.

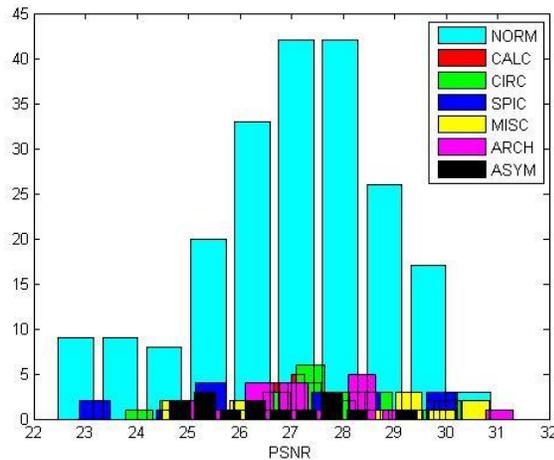


Figura 3. Histograma de los valores PSNR entre imagen original y filtrada para cada tipo de anomalía: NORM (normal), CALC (calcificación), CIRC (bien definida o circunscrita), SPIC (masa espigada), MISC (otras masas mal definidas), ARCH (distorsión estructural), ASYM (asimetría).

Como podemos ver en la figura 3, el histograma según tipo de anomalía, existe una diferencia de altura acusada entre las masas normales y el resto, debido a que no han sido normalizados los valores en función de la frecuencia de aparición. La distribución de nuevo parece seguir una distribución normal, aunque se disponen de pocos datos para los casos no normales.

De nuevo, en el histograma según diagnóstico (figura 4), la distribución es normal. El valor medio de PSNR en todos los casos es 27.

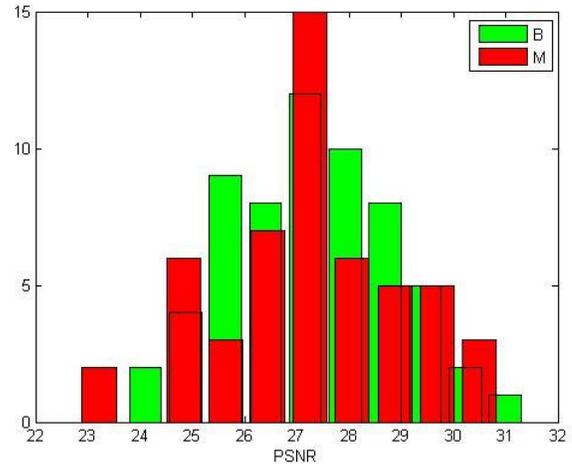


Figura 4. Histograma de los valores PSNR entre imagen original y filtrada para cada tipo de diagnóstico: B (benigno), M (maligno).

De manera paralela se ha realizado el mismo estudio histográfico expuesto, esta vez comparando la imagen filtrada con la contaminada a fin de comprobar si, efectivamente, la imagen filtrada se parece más a la original que a la ruidosa. Los resultados obtenidos son comparables en cuestión de distribución y el PSNR obtenido como media se sitúa en torno a 17, lo que nos confirma que la imagen resultante es adecuada y el filtro puede considerarse eficaz.

IV. CONCLUSIONES

Es este estudio hemos presentado los resultados, en términos del PSNR obtenido, de filtrado de imágenes según tipo de tejido, anomalía y diagnóstico.

Se ha demostrado que el filtro funciona correctamente ya que los valores del PSNR que comparan imagen original y filtrada son mejores que los valores para la imagen ruidosa y filtrada.

Se ha comprobado que no existe correlación entre el diagnóstico de la mamografía y el funcionamiento del filtro, incluyendo en este diagnóstico el en tipo de tejido, el tipo de masa y la benignidad o malignidad de la masa, ya que las distintas distribuciones se centran en el mismo valor de PSNR.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el proyecto ANITRAN PROMETEO/2010/039 de la Generalitat Valenciana, por el proyecto del Ministerio de Ciencia e Innovación (TIN2008-06570-C04-04) y por la spin-off Titania (Grupo Dominguis).

REFERENCIAS

1. J.C. Russ. *The Image Processing Handbook*, Fifth Edition. CRC Press, December 2006.
2. M. Bertero and P. Boccacci. *Introduction to Inverse Problems in Imaging*. CRC Press, January 1998.
3. F. Catté, P. Lions, J. Morel, and T. Coll. Image selective smoothing and edge detection by nonlinear diffusion. *SIAM Journal on Numerical Analysis*, 29(1):182-193, February 1992.
4. L.I. Rudin, S. Osher, and E. Fatemi. Nonlinear total variation based noise removal algorithms. *Physica D: Nonlinear Phenomena*, 60(1-4):259-268, November 1992.
5. J. Weickert, B.M.T.H. Romeny, and M.A. Viergever. Efficient and reliable schemes for nonlinear diffusion filtering. *IEEE Transactions on Image Processing*, 7(3):398-410, March 1998.
6. A. Marquina and S. Osher. Explicit algorithms for a new time dependent model based on level set motion for nonlinear deblurring and noise removal. *SIAM Journal on Scientific Computing*, 22(2):387-405, January 2000.
7. T. Chan, A. Marquina, and P. Mulet. High-order total variation-based image restoration. *SIAM Journal on Scientific Computing*, 22(2):503-516, January 2000.
8. S.L. Keeling. Total variation based convex filters for medical imaging. *Applied Mathematics and Computation*, 139(1):101-119, July 2003.
9. J. Weickert. Efficient image segmentation using partial differential equations and morphology. *Pattern Recognition*, 34(9):1813-1824, September 2001.
10. P. Mrázek and M. Navara. Selection of optimal stopping time for nonlinear diffusion filtering. *International Journal of Computer Vision*, 52(2-3):189-203, May 2003.
11. D.L. Donoho. De-noising by soft-thresholding. *IEEE Transactions on Information Theory*, 41(3):613-627, May 1995.
12. S. Morillas, V. Gregori, and A. Hervas. Fuzzy peer groups for reducing mixed gaussian-impulse noise from color images. *IEEE Transactions on Image Processing*, 18(7):1452-1466, July 2009.
13. J. Arnal, L.B. Sucar, M.G. Sanchez, and V. Vidal. Parallel filter for mixed gaussian-impulse noise removal. In *Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, 2013, pages 236-241, September 2013.
14. J. Suckling et al. The mammographic image analysis society digital mammogram database. In *Excerpta Medica*, pages 375-378, 1994.
15. E. Parceró, D. Segrelles, V. Vidal, I. Blanquer, G. Verdu. Towards Grid Environment to Perform Filtering Techniques for Improving Medical Images: an Use case of Mammographic Images. *Ibergrid 2014*, pp: 183-192, September 2014.
16. J. Astola, P. Haavisto, and Y. Neuvo. Vector Median Filters, *Proc. IEEE*, vol. 78, no. 4, pp. 678-689, 1990.