

# Método para visualización simultánea en imagen de rayos X de tejidos de muy diferente densidad

I. García Barquero<sup>1,2</sup>, M. Desco Menéndez<sup>1,2,3,4</sup>, M. Abella García<sup>1,2,3</sup>

<sup>1</sup> Depto. Bioingeniería e Ingeniería Aeroespacial, Universidad Carlos III de Madrid, España, ingarcia@pa.uc3m.es, {monica.abella, manuel.desco}@uc3m.es

<sup>2</sup> Instituto de Investigación Sanitaria Gregorio Marañón, Madrid, España, {igarcia, desco, mabella}@hggm.es

<sup>3</sup> Centro Nacional de Investigaciones Cardiovasculares Carlos III (CNIC), Madrid, España

<sup>4</sup> Centro de investigación en red en salud mental (CIBERSAM), Madrid, España

## Resumen

*A pesar del valor clínico de la imagen plana por rayos X, en estudios con tejidos de muy diferente densidad, como el tórax, no es posible obtener buen contraste en todas las estructuras de manera simultánea. Durante décadas se han estudiado algoritmos de mejora de contraste pero la mayoría son insuficientes para estos casos.*

*En este trabajo presentamos un método semi-automático de mejora de contraste para imágenes de rayos-X de tejidos de muy diferente densidad. La imagen final se obtiene a partir de la combinación de dos imágenes con mejora de contraste en tejido blando y denso por separado. Los pesos se calculan de forma automática maximizando la entropía de la imagen final.*

*Los resultados muestran que el algoritmo propuesto ofrece una mejora simultánea de contraste en ambos tipos de tejido en comparación con los métodos tradicionales.*

## 1. Introducción

Desde su descubrimiento, la imagen de rayos X ha sido una herramienta clave para el diagnóstico; sin embargo, a pesar de su valor clínico, ofrece un contraste en tejido blando pobre. Durante décadas se han estudiado diferentes formas de mejorar el contraste de imágenes con bajo rango dinámico o para destacar detalles que, de otra forma, permanecerían escondidos [1]. De esta forma, podemos ayudar a los radiólogos a interpretar las imágenes con más precisión. Normalmente, estas técnicas se enfocan en mejorar el contraste en un rango determinado del histograma, lo que es insuficiente en estudios con tejidos de muy diferente densidad como son los de tórax, donde tenemos tejido muy poco denso como los pulmones y tejido muy denso como la columna.

Las técnicas de mejora de contraste pueden dividirse según el dominio en que actúan: espacial o de la frecuencia [1]. Las primeras se basan en la manipulación directa de los píxeles de la imagen mientras que en las segundas hay que transformar la imagen (con una transformada de Fourier o Wavelet, por ejemplo), realizar el procesamiento en ese dominio y aplicar la transformada inversa.

Entre los algoritmos en dominio espacial encontramos la ecualización de histograma (HE), que consiste en uniformar el histograma de la imagen de forma que todos los niveles de gris tengan la misma probabilidad de ocurrencia [1]. Este método produce una mejora de

contraste general pero no permite potenciar una estructura concreta. Para hacer frente a esta limitación, se han propuesto mejoras como la ecualización de bi-histograma (BBHE) [2], que preserva el brillo medio de la imagen; la ecualización dinámica de histograma (DHE) [3], que ecualiza sub-histogramas de la imagen; o la ecualización adaptativa con limitación de contraste (CLAHE) [4], que aplica la ecualización de forma adaptativa y recorta los intervalos del histograma para evitar zonas muy oscuras y/o brillantes.

Otro algoritmo en dominio espacial muy utilizado en la literatura es la corrección gamma (GC), que consiste en una transformación de los niveles de gris de la imagen de acuerdo a una función exponencial cuya curvatura se puede modular. Al igual que ocurre con las técnicas HE, la GC se puede aplicar a sub-histogramas o de forma adaptativa [5, 6]. Estos algoritmos nos permiten mejorar la visualización de tejidos concretos de la imagen a costa de perder contraste en otras estructuras.

Los métodos HE aumentan el rango dinámico de la imagen por lo que, necesariamente, asigna valores irreales a ciertos píxeles que pueden otorgarle un aspecto poco natural. Sin embargo, los métodos GC sólo actúan sobre el contraste de la imagen. En el caso concreto de trabajar con imagen médica, lo deseable es que la información no se vea modificada siendo los métodos GC más adecuados que las técnicas HE.

En este trabajo proponemos un método semi-automático basado en el trabajo de [7], que busca mejorar el contraste de las imágenes de rayos X potenciando la visualización simultánea de tejido blando y denso. La imagen procesada se obtiene a partir de la combinación lineal de dos imágenes resultado de aumentar el contraste en tejido blando y denso respectivamente. Tanto los parámetros de la combinación lineal como los que definen las curvaturas de las funciones gamma se obtienen automáticamente maximizando la entropía de la imagen final en una región de interés (ROI) seleccionada por el usuario.

## 2. Método propuesto

El método propuesto busca maximizar la entropía de la imagen de forma global, considerando la imagen entera, o local, en una ROI seleccionada por el usuario. La imagen procesada se obtiene a partir de la combinación lineal de

dos imágenes resultado de aumentar el contraste en tejido blando y denso respectivamente. A excepción de la selección de la ROI, que requiere la intervención del usuario, el algoritmo está totalmente automatizado.

La Figura 1 muestra el flujo de trabajo del método propuesto. En primer lugar, se duplica la imagen original ( $I_{original}$ ) buscando en una de ellas el realce de los huesos ( $I_{hueso}$ ) y en la otra del tejido blando ( $I_{blando}$ ) por medio de una corrección gamma ( $\gamma$ ). A continuación, ambas imágenes se combinan aplicándoles un cierto peso ( $\alpha$ ).

$$I_{hueso} = (I_{original})^{\gamma}, \quad \gamma > 1 \quad (1)$$

$$I_{blando} = (I_{original})^{\gamma^{-1}}, \quad \gamma > 1 \quad (2)$$

$$I_{final} = \alpha \cdot I_{hueso} + (1 - \alpha) \cdot I_{blando} \quad (3)$$

Para automatizar el algoritmo, buscamos la combinación de pesos y parámetros gamma que maximizan la entropía de la imagen final (global o localmente). Para conseguirlo, se busca qué parámetro de contraste es el óptimo para cada peso que estemos evaluando.

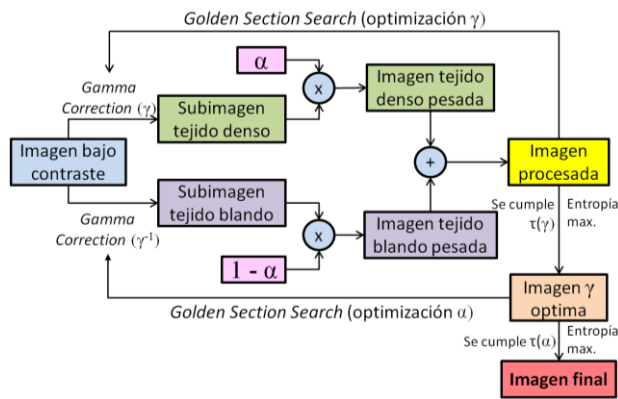


Figura 1. Flujo de trabajo del algoritmo

## 2.1. Realce de contraste

El realce de contraste en las subimágenes se basa en el algoritmo GC, que transforma los niveles de gris de la imagen de entrada de acuerdo a una función exponencial.

$$T(l) = l_{max} \cdot \left(\frac{l}{l_{max}}\right)^{\gamma} \quad (4)$$

donde  $T(l)$  es la transformación del nivel de gris  $l$ -ésimo,  $l_{max}$  es el máximo nivel de gris de la imagen de entrada y  $\gamma$  es el parámetro que controla la curvatura de la función de transformación.

## 2.2. Algoritmo de optimización

Los parámetros de la función gamma que definen su curvatura ( $\gamma$  para imagen de hueso y  $\gamma^{-1}$  para tejido blando) así como los pesos por los coeficientes de la combinación lineal de las subimágenes ( $\alpha$  para imagen de hueso y  $1-\alpha$  para tejido blando) se obtienen aplicando una técnica de optimización conocida como “Golden Section Search” [8]. Este algoritmo busca el máximo (o mínimo) de una función unimodal dentro de un intervalo cerrado

$[a_0, b_0]$ , como muestra la Figura 2. Iterativamente, se evalúan distintos puntos de la función reduciendo el intervalo  $[a_i, b_i]$  hasta que se cumple una condición de terminación  $\tau$ .




Figura 2. Punto “y” encontrado en una función unimodal mediante el algoritmo Golden Section Search después de  $i+1$  iteraciones

Dado que la entropía está relacionada con la homogeneidad de los niveles de gris, siendo más baja cuanto menos niveles de grises diferentes tiene la imagen (es nula si la imagen es enteramente homogénea), una imagen con buen contraste tendrá una entropía alta [9]. Por tanto, como función de coste a maximizar hemos elegido la entropía, que se define como:

$$H(\alpha, \gamma) = - \sum P_i \cdot \log(P_i) \quad (5)$$

donde  $P_i$  es la función probabilidad de encontrar el nivel de gris  $i$ -ésimo entre los  $n$  posibles valores de nivel de gris de la imagen

La selección de los valores iniciales de  $\gamma$ ,  $\alpha$  y  $\tau$  se ha hecho en base a los propuestos en [7]. Los rangos son  $\gamma \in [1, 4]$ ,  $\alpha \in [0, 1]$  y la condición de terminación para ambos casos es  $\tau(\gamma) = \tau(\alpha) = 50$  iteraciones.

En la Figura 3 se muestra el proceso de reducción del intervalo para el parámetro  $\alpha$  (siendo similar para el parámetro  $\gamma$ ).




Figura 3. Reducción del intervalo del algoritmo Golden Section Search para las dos primeras iteraciones

En cada iteración se evalúa la entropía de la imagen para dos valores de  $\alpha$  intermedios, seleccionados de forma que la reducción del rango sea simétrica, es decir:

$$a_1 - a_0 = b_0 - b_1 = \rho \cdot (b_0 - a_0) \quad (6)$$

donde  $\rho$  ha de ser menor de  $\frac{1}{2}$ . El valor escogido para nuestro método es el recomendado en [8]:

$$\rho = \frac{3 - \sqrt{5}}{2} \quad (7)$$

siendo, por tanto:

$$a_1 = 0.382 \quad (8)$$

$$b_1 = 0.618 \quad (9)$$

Si  $H(a_1, \gamma) > H(b_1, \gamma)$ , la máxima entropía se dará para  $\alpha$  perteneciente al rango  $[a_0, b_1]$ . Además,  $a_1$  se convertirá en uno de los nuevos puntos intermedios de la siguiente iteración ( $a_1 = b_2$ ) y el otro punto intermedio lo calcularemos como:

$$a_2 = a_0 + \rho \cdot (b_1 - a_0) = 0.236 \quad (10)$$

En caso contrario, el máximo estará en el rango  $[a_1, b_0]$ ,  $b_1$  será uno de los puntos intermedios ( $b_1 = a_2$ ) y

$$b_2 = a_1 + (1 - \rho) \cdot (b_0 - a_1) = 0.764 \quad (11)$$

Este proceso se repetirá iterativamente hasta que se cumpla el criterio de parada, es decir, hasta que el intervalo se reduzca tantas veces como iteraciones se han fijado.


### 3. Evaluación

Para evaluar el algoritmo hemos utilizado imágenes reales de rayos-X:

- Imagen de tórax postero-anterior de un maniquí antropomórfico modelo PBU-60 comercializado por la empresa Kyoto Kagaku. La imagen tiene contraste deficiente en hueso, tejido blando y pulmón,
- Imagen de tórax y abdomen lateral de perro cedida por el Hospital Clínico Veterinario de la Universidad Complutense de Madrid. La imagen tiene bajo contraste en tejido blando.


La ROI seleccionada en cada caso está centrada en la zona donde tenemos especial interés en aumentar el contraste: la columna vertebral en la imagen de maniquí y el abdomen en la de perro. Las imágenes obtenidas mediante nuestro método se han comparado con las resultantes del algoritmo GC en las que se ha potenciado la visualización de tejido denso en el primer caso y de tejido blando en el segundo.

En la Figura 4 se muestra la imagen original de tórax de maniquí y los resultados de aplicar el algoritmo GC para visualizar mejor el hueso y el método propuesto.




**Figura 4.** Imagen de tórax de maniquí (A) e imágenes resultado de aplicar GC (B) y el método propuesto (C)

Podemos apreciar que el aumento de contraste en columna con GC supone una disminución de contraste en pulmón mientras que con el algoritmo propuesto se consigue aumentar el contraste en ambas estructuras de forma simultánea. La siguiente Figura 5 muestra dos ROIs ampliadas en pulmón y de columna, donde se puede apreciar mejor este efecto.




**Figura 5.** ROI pulmonar ampliada en imagen GC (A) e imagen con el método propuesto (B). ROI de columna ampliada en imagen GC (C) e imagen con el método propuesto (D)

En la Figura 6 se muestra la imagen original de tórax y abdomen de perro y los resultados de aplicar el algoritmo GC para visualizar mejor el tejido blando y el método propuesto.



**Figura 6.** Imagen de tórax y abdomen de perro (A) e imágenes resultado de aplicar GC (B) y el método propuesto (C)

Ambos algoritmos mejoran el contraste en tejido blando pero el método propuesto mantiene un contraste adecuado entre el hueso y el tejido blando mientras que el algoritmo GC lo disminuye. Este efecto se puede apreciar mejor en la Figura 7, que muestra una ampliación de una ROI pulmonar-cervical y de una ROI abdominal.



**Figura 7.** ROI pulmonar-cervical ampliada en imagen GC (A) e imagen con el método propuesto (B). ROI abdominal ampliada en imagen GC (C) e imagen con el método propuesto (D)

#### 4. Discusión

En este trabajo proponemos un nuevo método de mejora simultánea de contraste en tejidos blando y denso para imágenes de rayos-X. Para ello se obtienen dos imágenes, cada una con buen contraste en uno de los tejidos, que se combinan linealmente. Los coeficientes de esta combinación se obtienen de forma automática maximizando la entropía.

El método permite maximizar la entropía global, calculando este parámetro para todos los píxeles de la imagen en conjunto, o la entropía local, seleccionando una ROI de interés de la imagen.

La principal ventaja del método propuesto es que permite la mejora de contraste tanto en tejido blando y hueso de forma simultánea, al contrario de lo que ocurre cuando se emplean métodos tradicionales como la GC. Esto es particularmente importante en caso de imágenes con tejidos de muy diferente densidad, como las de estudios de tórax, en las que tenemos al mismo tiempo tejido muy denso (columna) y tejido muy poco denso (pulmones).

#### 5. Trabajo futuro

El algoritmo GC con el que se obtienen las subimágenes de tejido blando y denso puede sustituirse fácilmente por otras funciones que tengan el mismo objetivo, por ejemplo, las funciones sigmoidea o lineal por tramos. Sería conveniente analizar los resultados obtenidos con dichas funciones para encontrar aquella que consiga ofrecer el mayor contraste en ambos tipos de tejido simultáneamente.

#### Agradecimientos

Este trabajo ha sido financiado por el Ministerio de Economía, Industria y Competitividad (proyectos DPI2016-79075-R) y por el Instituto de Salud Carlos III (DTS17/00122).

#### Referencias

- [1] R. E. W. R.C. Gonzalez, Digital Image Processing. New Jersey: Prentice-Hall, Inc., 2002.
- [2] Y. T. Kim, "Contrast enhancement using brightness preserving bi-histogram equalization," *Ieee Transactions on Consumer Electronics*, vol. 43, pp. 1-8, Feb 1997.
- [3] M. Abdullah-Al-Wadud, et al., "A dynamic histogram equalization for image contrast enhancement," *Ieee Transactions on Consumer Electronics*, vol. 53, pp. 593-600, May 2007.
- [4] S. M. Pizer, et al., "ADAPTIVE HISTOGRAM EQUALIZATION AND ITS VARIATIONS," *Computer Vision Graphics and Image Processing*, vol. 39, pp. 355-368, Sep 1987.
- [5] S. C. Huang, et al., "Efficient Contrast Enhancement Using Adaptive Gamma Correction With Weighting Distribution," *Ieee Transactions on Image Processing*, vol. 22, pp. 1032-1041, Mar 2013.
- [6] D. Zhang, et al., Histogram Partition based Gamma Correction for Image Contrast Enhancement. New York: Ieee, 2012.
- [7] G. Jiang, et al., "Image contrast enhancement with brightness preservation using an optimal gamma correction and weighted sum approach," *Journal of Modern Optics*, vol. 62, pp. 536-547, 2015.
- [8] S. H. Z. Edwin K. P. Chong An Introduction To Optimization, 2nd ed.: Wiley-Interscience, 2001.
- [9] B. A. Khellaf A., Dupoisot H., "Entropic Contrast Enhancement," *IEEE Trans Med Imaging*, vol. 10, pp. 589-92, 1991.