



LA FORMACIÓN DE INGENIEROS:  
UN COMPROMISO PARA EL  
DESARROLLO Y LA SOSTENIBILIDAD

15 al 18  
DE SEPTIEMBRE

20  
20

[www.acofi.edu.co/eiei2020](http://www.acofi.edu.co/eiei2020)

# NUEVO MÉTODO PARA LA ESTIMACIÓN DE RUIDO GAUSSIANO EN IMÁGENES BIOMÉDICA

**Manuel Guillermo Forero Vargas, Sergio Luis Alejandro Miranda Rojas**

**Universidad de Ibagué  
Ibagué, Colombia**

## Resumen

En el estudio de imágenes médicas incluyendo las de microscopía, es de gran importancia que éstas tengan la menor cantidad de ruido posible, con el objetivo de que procesos posteriores, tanto en análisis como en la visualización no se han afectados. En la práctica, siempre se tendrá ruido, puesto que es inherente al proceso de la adquisición. Cabe resaltar, que el ruido más común encontrado en imágenes médicas es el gaussiano. Por lo tanto, se requiere mejorar la calidad de la imagen eliminando el ruido de manera eficiente, para ello cada día se desarrollan diferentes técnicas de filtrado, siendo las más avanzadas las que requieren el valor aproximado del nivel del ruido de la imagen, lo que hace necesario el uso de métodos de estimación de ruido. En este trabajo se comparan 5 métodos, uno de ellos propuesto por los autores basado en algunos de los principios trabajados en los otros. Estos fueron implementados en lenguaje Java como plugins del programa de libre acceso ImageJ. La práctica se desarrolló con 12 imágenes médicas contaminadas con diferentes niveles de ruido gaussiano. Los métodos son comparados evaluando el error cuadrático medio de la estimación y el tiempo de cómputo. Los mejores resultados, en cuanto hace al error de estimación fueron obtenidos con el método propuesto, siendo no mayor a 0.68.

**Palabras clave:** ruido gaussiano; suavización de imágenes; filtrado de imágenes; descomposición en valores singulares; estimación de ruido

## Abstract

*In the study of medical images, including of microscopy, it is of great importance that these have the least amount of noise possible, with the objective that the subsequent processes, both analysis and visualization, have not been affected. In practice, there will always some noise, since it is*

*inherent to the acquisition process. It should be noted, that the most commonly found noise in medical imaging is Gaussian. Therefore, it is necessary to improve the quality of the image by eliminating noise in an efficient form. To this end, different filtering techniques are developed every day, the most advanced being those that require the approximate value of the image noise level, which makes necessary the use of noise estimation methods. In this paper five methods are compared, one of them proposed by the authors based on some of the principles worked in the others. They were implemented in Java language as plugins of the free access program ImageJ. The evaluation was developed with 12 medical images contaminated with different levels of Gaussian noise. The methods were compared by evaluating the mean square error of the estimation and the computation time. Best results, in terms of estimation error, were obtained with the proposed method, being no greater than 0.68.*

**Keywords:** *gaussian noise; image smoothing; image filtering; singular value decomposition; noise estimation*

## 1. Introducción

Un gran problema en el procesamiento de imágenes es el ruido, el cual afecta el análisis de la información. En técnicas avanzadas como de suavización y de detección de bordes requieren una estimación del nivel de ruido para obtener mejores resultados, ya que de esta forma sus parámetros pueden ajustarse automáticamente para que el filtrado sea más o menos agresivo, o en el caso de los detectores de bordes, para considerar como bordes sólo aquellos cambios bruscos que sean mayores que los producidos por el ruido. Estas técnicas comprenden: congruencia de fase para detectar bordes (Kovesi, 1999), filtros suavizantes como el operador anisotrópico (Perona, *et al.*, 1892), y algunos considerados de última generación, basados en la modelización dispersa como el K-SVD (Aharon, *et al.*, 2006).

El tipo de ruido más estudiado en la literatura es el gaussiano, ya que se presenta con más frecuencia en las imágenes digitales, entre ellas médicas. En general, las técnicas de estimación de ruido pueden clasificarse en dos conjuntos, según se efectúen en el dominio espacial o en el de la frecuencia. Las técnicas espaciales pueden ser agrupadas en tres, las que dividen la imagen en bloques, las que aplican filtrado y las híbridas (Shin, *et al.*, 2005). En principio, las técnicas basadas en bloques tratan de identificar zonas uniformes cuyas variaciones de intensidad se deben idealmente sólo al ruido, y luego se utilizan herramientas estadísticas para estimar el ruido. Las que se basan en filtros obtienen una imagen al aplicar una máscara pasa alto o de pasa de banda sobre la original para distinguir el ruido de la señal y posteriormente estiman el nivel de ruido restante en la imagen obtenida. Las técnicas en las que la estimación se hace en el dominio de la frecuencia efectúan un análisis del espectro de la imagen utilizando una transformación de decorrelación, como la transformación de onda discreta.

En un estudio reciente (Forero, *et al.*, 2019) se comprobó que los métodos de estimación no proporcionan una buena estimación en la gran mayoría de los casos y, en general, los métodos híbridos proporcionan una mejor estimación. Entre estos métodos se encuentra un método de dos etapas desarrollado por (Turajlić, 2017). Primero, la imagen se filtra con un filtro pasa banda y la

imagen resultante se divide en bloques no superpuestos de  $64 \times 64$  píxeles. La dispersión aproximada de cada bloque se calcula entonces utilizando una ecuación que reduce en gran medida el costo del cálculo en comparación con el cálculo de la desviación estándar, se continúa con el 15% de los bloques. Segundo, los bloques seleccionados se subdividen según la desviación estándar mínima obtenida, por último, el 85% de los sub-bloques con menor dispersión se utilizan para obtener la estimación del nivel de ruido

En el presente artículo se propone un nuevo método de estimación a partir de la aplicación de mejoras sobre el método de Turajlić (2017). Así mismo, su eficiencia es evaluada por medio de un estudio comparativo con otros cuatro métodos usando imágenes médicas contaminadas con ruido gaussiano.

## 2. Métodos y Materiales

### 2.1. Materiales

Para el estudio sobre el factor de ajuste para la segunda etapa en el método propuesto se usaron 20 imágenes monocromáticas de  $512 \times 512$  píxeles, dos sintéticas y dieciocho tomadas de (CVG - UGR - Image database, n.d.), (ImageProcessingPlace, n.d.) y (USC-SIPI, n.d.). En el estudio comparativo se utilizan 12 imágenes médicas monocromáticas de  $512 \times 512$  píxeles (ver figura 1) (National Library Medicine, n.d.) (National Cancer Institute USA, n.d.). Las imágenes fueron contaminadas con diferentes niveles de ruido gaussiano, desde  $\sigma = 5$  hasta  $\sigma = 40$  en incrementos de 5, para obtener la función del factor de ajuste. Los algoritmos se escribieron en Java como plugins del programa de libre acceso ImageJ. Las pruebas fueron desarrolladas en un computador Intel Core i5-8250U CPU 1.6 GHz 1.8GHz con 8 GB de RAM.

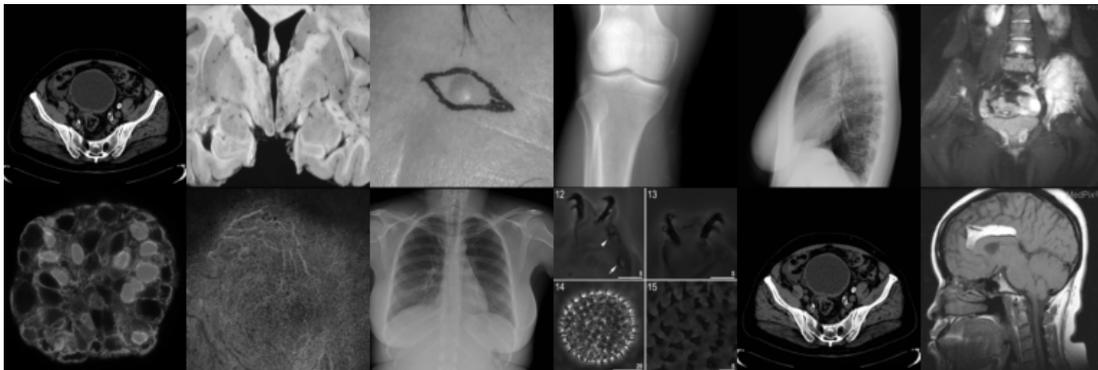


Figura 1. Imágenes médicas usadas en el estudio comparativo.

### 2.2. Blocks1

El método híbrido “Block-Based Noise Estimation Using Adaptive Gaussian Filtering” (nombrado para el estudio Blocks1), es desarrollado en el artículo de Shin, *et al.* (2005). Inicialmente, divide la imagen en bloques no superpuestos de  $3 \times 16$  píxeles. Para cada bloque se calcula su desviación estándar y se selecciona la mínima ( $\sigma_{min}$ ). Luego se encuentran los bloques homogéneos aplicando

la condición de la Ecuación 1. Continúa calculando los coeficientes de un filtro gaussiano a partir de  $\sigma_{min}$ . Luego, se aplica el filtro a la imagen y finalmente se realiza la estimación de ruido, dada por el promedio de las desviaciones estándar de los bloques homogéneos de la imagen dada por la diferencia entre las imágenes de entrada y filtrada.

$$B = \begin{cases} m_{i,j} - 3\sigma_{min} \geq 0 \wedge m_{i,j} + 3\sigma_{min} \leq 255 \\ \{b_{i,j} | \lfloor \sigma_{i,j} \rfloor = \lfloor \sigma_{min} \rfloor\}, & \text{if } \lfloor \sigma_{min} \rfloor = \langle \sigma_{min} \rangle \\ \{b_{i,j} | \langle \sigma_{i,j} \rangle = \langle \sigma_{min} \rangle\}, & \text{othercase} \end{cases} \quad (1)$$

Donde  $m$  es el promedio de intensidad del bloque,  $B$  es el conjunto de bloques homogéneos,  $b$  el bloque a analizar,  $\sigma$  su desviación estándar y  $i, j$  las coordenadas del bloque sobre la imagen.

### 2.3. Blocks2

Técnica propuesta por Turajlić, *et al.* (2017), llamada "Noise Estimation Using Adaptive Gaussian Filtering And Variable Block Size Image Segmentation" (nombrado para el estudio Blocks2), la cual se compone de dos etapas. En la primera se subdivide la imagen en bloques de 32x32 o 64x64 pixeles, y luego se siguen los pasos ya visto en Blocks1, pero se diferencia en que el proceso se continua con la imagen diferencia y encontrando la desviación estándar mínima  $\sigma_{Min}^{(1)}$  entre los bloques homogéneos. En la segunda etapa, primero se subdividen los bloques homogéneos en forma adaptativa, en sub-bloques de lado igual a  $\sigma_{Min}^{(1)}$ . Se calcula la desviación estándar en cada sub-bloque y se encuentra la mínima  $\sigma_{min}^{(2)}$ . Luego se seleccionan los sub-bloques homogéneos cuya desviación estándar no debe superar a  $\sigma_{min}^{(2)} + 1.8$ . Por último, se estima el ruido promediando las dispersiones de los sub-bloques homogéneos.

### 2.4. SVD

"Additive White Gaussian Noise Level Estimation in SVD Domain for Images" (para el estudio se nombra SVD) es un método desarrollado por Wei Liu, *et al.* (2011). Usa como herramienta principal la descomposición en valores singulares (SVD) sobre la imagen. Es basado en la teoría de que los valores singulares más pequeños son relacionados con el ruido y, por ende, puede usarse para estimar la señal contaminante. Para el proceso del algoritmo es necesario establecer dos parámetros constantes  $M$  y  $\alpha$ .  $M$  corresponde al número de valores singulares más pequeños empleado para la evaluación. Los autores sugieren usar  $\frac{3}{4}$  del total, donde el número total de valores singulares es equivalente al ancho de la imagen. El valor de  $\alpha$  es igual a la pendiente de la recta que se ajusta a los promedios de los valores singulares para diferentes niveles de ruido agregados, que van de 10 a 50 en incrementos de 5 (ver Figura 2) de una imagen de un tamaño específico.

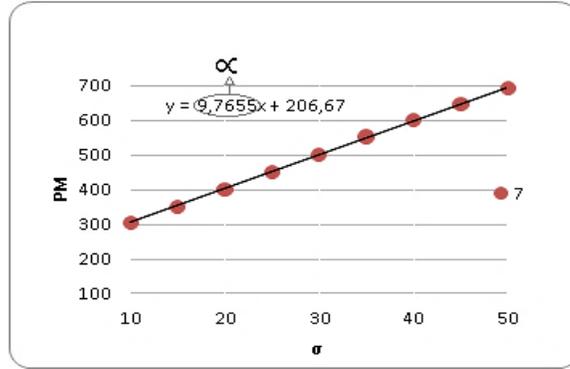


Figura 2. Ejemplo de cálculo de  $\alpha$ , pendiente de la recta que mejor se ajusta a los promedios de los  $M$  valores singulares más pequeños de una imagen contaminada con diferentes niveles de ruido.

El algoritmo consta de los siguientes pasos: Inicialmente se escoge el valor de  $M$  y  $\alpha$ , tomando los valores sugeridos de  $\frac{3}{4}$  y 13.8 para imágenes de 512x512 píxeles. Luego se realiza la SVD sobre toda la imagen y se calcula el promedio de los  $M$  valores singulares más pequeños ( $PM$ ). Se agrega a la imagen de entrada un ruido con desviación estándar igual a  $\sigma = 19$ . A continuación, se realiza la SVD sobre esta nueva imagen, obteniendo el promedio de los  $M$  valores singulares más pequeños ( $P1M$ ). Finalmente, la estimación del ruido se calcula mediante la siguiente ecuación:

$$\hat{\sigma} = \frac{\alpha \sigma_1^2}{2(P1M - PM)} - \frac{P1M - PM}{2\alpha}$$

### 2.5. Fast

Método titulado “A Fast Noise Level Estimation Algorithm Based on Adaptive Image Segmentation and Laplacian Convolution” propuesto por Turajlić (2017). Comprende dos etapas. En la primera, se convoluciona la imagen con un filtro pasa banda  $h$  (Ecuación 2). Luego se subdivide la imagen en bloques no superpuestos de 64x64 píxeles, se calcula desviación estándar en cada bloque mediante la Ecuación 3, que permite realizar el cálculo de manera más rápida que mediante la ecuación estándar. Luego se obtiene la desviación mínima y se toma el 15% de los bloques más homogéneos, es decir aquellos que tienen las desviaciones más pequeñas.

$$h = \begin{bmatrix} 1 & -2 & 1 \\ -2 & 4 & -2 \\ 1 & -2 & 1 \end{bmatrix} \tag{2}$$

$$\hat{\sigma} = \sqrt{\frac{\pi}{2}} \frac{1}{6(W-2)(H-2)} \sum_{Image} |I(x,y) * h| \tag{3}$$

donde  $W$  y  $H$  corresponden al ancho y el alto del bloque a analizar respectivamente.

En la segunda etapa, los bloques homogéneos se subdividen en bloques cuadrados de lado  $\sigma_{min}^{(1)} * 1.9$ , siendo 1.9 una constante hallada de forma empírica por el autor. Luego, se calcula la dispersión de cada sub bloque empleando nuevamente la Ecuación 3. Finalmente, se encuentra el 85% de los sub bloques con menor desviación estándar y se toma como estimación del ruido el promedio de estas dispersiones.

## 2.6. Propuesto

El método propuesto se desarrolla a partir de cambios realizados sobre el método Fast. En este, en la primera etapa, se encuentra el bloque de 64x64 píxeles que tiene la mínima dispersión  $\sigma_{min}$ . Puesto que la dispersión de un bloque puede ser baja que las otras, si el bloque está ubicado en una región muy clara o muy oscura de la imagen, puesto que la intensidad no puede caer por fuera del rango dinámico disponible  $[0, L-1]$ , donde L es el máximo nivel de gris de la imagen, lo cual puede llevar a una estimación errónea del nivel de ruido, como se puede apreciar en la Figura 3. Para eliminar este problema, se verifica que los valores dados por  $\mu \pm 3 \sigma$  de cada sub bloque se encuentren dentro del rango dinámico de la imagen, empleando la Ecuación (3) para el cálculo de la dispersión. El bloque se descarta si las intensidades de los píxeles no están dentro del rango. En este caso, se busca el siguiente bloque con menor dispersión que cumpla con el rango dado por la media. Una vez encontrada, su dispersión se toma como  $\sigma_{min}$ .

En la segunda etapa se aplicó un cambio sobre la Ecuación 3, ya que presentaba un error apreciable en la estimación del ruido sobre los sub-bloques homogéneos. Por lo cual se utilizó un factor de ajuste ( $AF$ ) en lugar del 6 ubicado en el denominador. Para hallar un factor de ajuste adecuado, se realizó un estudio con 20 imágenes, 2 sintéticas y 18 naturales contaminadas con distintos niveles de ruido gaussiano de 5 a 40 en incrementos de 5. Se efectuaron dos ensayos por imagen para el mismo nivel de ruido donde el valor de  $AF$  cambia de 4 a 10 en incrementos de 0,25. Después se tomó el valor de ajuste que proporcionaba la mejor estimación de ruido para cada imagen, considerando que el ruido final de cada imagen está dado por el ruido natural más el ruido añadido ( $\sigma_{final} = \sqrt{(\sigma_{inicial})^2 + (\sigma_{añadido})^2}$ ).

La Figura 4 indica el grupo de valores de ajuste obtenidos por cada imagen, para cada nivel de ruido agregado. Se buscó la función que mejor se aproxima al conjunto de puntos para encontrar el valor de ajuste  $AF$  de manera automática. Se adoptaron dos aproximaciones para este objetivo. En el primero se empleó una función polinómica de tercer grado y en el segundo una función exponencial, mostradas en la Figura 4 e identificadas como Exp y Pol. En ambos enfoques, la desviación estándar mínima de la primera etapa  $\sigma_{min1}$  se fija como la variable independiente. Las funciones obtenidas se presentan en las ecuaciones 4 y 5.

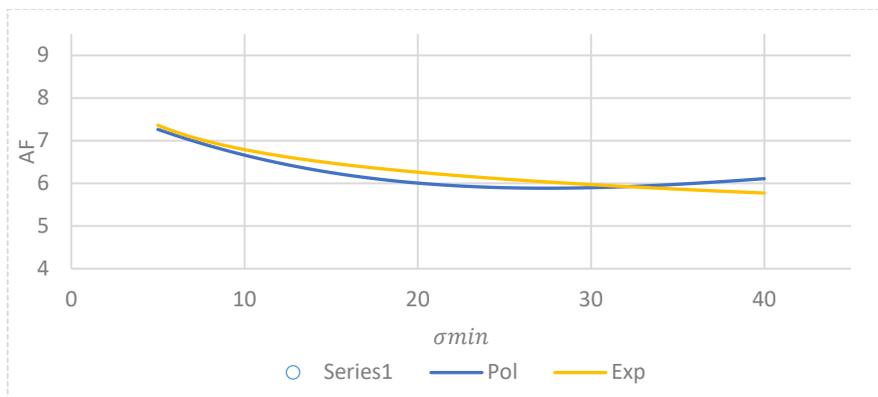


Figura 4. Funciones de aproximación a los puntos de factor de ajuste y dispersión mínima con los que se consiguió menor error en la estimación.

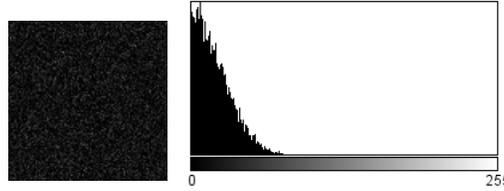


Figura 3. Zona oscura homogénea con un ruido agregado de  $\sigma = 25$  y su histograma. Como se puede observar en el histograma, la función probabilidad de ruido recortada, la estimación de ruido en la zona oscura es de  $\sigma = 25$ , lo que evidencia un error en la estimación.

$$A_f = -0.00003779\sigma_{min}^3 + 0.005\sigma_{min}^2 - 0.189\sigma_{min} + 8.09 \tag{4}$$

$$A_F = 8.8912(\sigma_{min1})^{-0.117} \tag{5}$$

### 3. Resultados

Para evaluar la eficiencia del método propuesto se comparó el error cuadrático medio (MSE) y el tiempo de ejecución con los cinco métodos antes mencionados para cuatro diferentes niveles de ruidos agregado (ver Tabla 1). Nótese que el método con menor MSE es el propuesto y nunca supera un valor de 0.8. Además, aplicando la aproximación exponencial para el cálculo del  $AF$  es mejor para los dos primeros niveles de ruido agregado y para los otros dos es mejor con la aproximación polinomio. No obstante, el método desarrollado es más lento que el propuesto por Turajlić, ya que en promedio aumenta en un poco más de 8 ms, algo lógico teniendo en cuenta las modificaciones realizadas. El método más rápido es Fast con 37.1 ms, seguido por Blocks1 con 41.1 ms, continúa el propuesto con 45.2 ms, luego Blocks2 con 84 ms y finalmente con 2.9 s está SVD.

Tabla 1. Resultados de error y tiempo de la estimación de ruido de los métodos mencionados en la sección 2 para los diferentes niveles de ruido agregado, aplicado sobre las 12 imágenes médicas.

Método	MSE				tiempo(ms)			
	$\sigma=5$	$\sigma=10$	$\sigma=15$	$\sigma=20$	$\sigma=5$	$\sigma=10$	$\sigma=15$	$\sigma=20$
<b>Blocks1</b>	1.005	4.294	13.266	31.294	49.5	39.7	38.0	38.5
<b>Blocks2</b>	3.489	1.723	2.446	0.903	57.0	74.3	93.8	111.1
<b>SVD</b>	7.736	6.366	5.974	5.376	2989.0	2959.7	2967.2	2983.3
<b>Fast</b>	3.357	2.518	7.184	17.498	38.0	36.6	36.8	37.2
<b>Propuesto Exp</b>	0.550	0.372	0.484	0.624	46.8	44.8	45.3	45.3
<b>Propuesto Pol</b>	0.673	0.404	0.386	0.579	44.5	45.1	44.5	46.4

### 4. Conclusiones

En este documento se compararon cinco métodos de estimación de ruido, mostrando que un método mejorado propuesto aquí, basado en el estimador de ruido de Turajlić, permite conseguir resultados más precisos, mejorando la estimación del nivel de ruido gaussiano. La primera mejora, consiste en descartar los bloques cuya función de ruido gaussiano está truncada, produciendo un error

indeseado en la estimación. Asimismo, dos propuestas, polinómica y exponencial, para el cálculo de un nuevo factor de ajuste permitieron mejorar aún más la precisión de la estimación, siendo similar, en ambos casos, el error cuadrático medio y el tiempo de cálculo.

## 5. Referencias

### Artículos de revistas

- Aharon, M., Elad, M., & Bruckstein, A. (2006). K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation. *IEEE Transactions on Signal Processing*, Vol. 54, No.11, pp. 4311-4322.
- Forero, M. G., & Miranda, S. L. (2019). Gaussian noise estimation methods in images. *Applications of Digital Image Processing XLII SPIE*. Vol. 11137, pp. 55.
- Kovesei, P. (1999). Image features from phase congruency. *Videre: Journal of computer vision research*, pp. 1-26.
- Liu, W., & Lin, W. (2013). Additive white gaussian noise level estimation in SVD domain for images. *IEEE Transactions on Image Processing*, Vol. 22, No.3, pp. 872–883.
- Perona, P., & Malik, J. (1990). Scale-Space and Edge Detection Using Anisotropic Diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 12, No. 7, 629–639.
- Shin, D. H., Park, R. H., Yang, S., & Jung, J. H. (2005). Block-based noise estimation using adaptive Gaussian filtering. *IEEE Transactions on Consumer Electronics*, Vol. 51, No 1, 218–226.
- Turajlić, E. (2017). A fast noise level estimation algorithm based on adaptive image segmentation and Laplacian convolution. *MIPRO 2017 - Proceedings*, pp. 486-491.
- Turajlic, E., & Begovic, A. (2017). Noise estimation using adaptive Gaussian filtering and variable block size image segmentation. *EUROCON 2017*, pp. 249–254.

### Fuentes electrónicas

- CVG - UGR - Image database. (n.d.). Consultado el 18 de mayo de 2020 en <http://decsai.ugr.es/cvg/dbimagenes/>
- ImageProcessingPlace. (n.d.). Consultado el 10 de febrero de 2020 en [http://www.imageprocessingplace.com/root\\_files\\_V3/image\\_databases.htm](http://www.imageprocessingplace.com/root_files_V3/image_databases.htm)
- National Cancer Institute USA. (n.d.). NCI Visuals Online: Search: Results. Consultado el 10 de febrero de 2020 en <https://visualsonline.cancer.gov/searchaction.cfm?topicid=g16>
- National Library Medicine. (n.d.). Openi. Consultado el 18 de febrero de 2020 en <https://openi.nlm.nih.gov/gridquery?q=ALL&it=xg&m=1&n=100>
- USC-SIPI. (n.d.). SIPI Image Database. Consultado el 12 de febrero de 2020 en <http://sipi.usc.edu/database/database.php>

## Sobre los Autores

- **Manuel Guillermo Forero Vargas:** Ing. Electrónico. Magister en Ing. Eléctrica. Área: Bioingeniería. Master en imágenes médicas y Doctor en Ing. Biomédica. Tutor semillero en Procesamiento de Imágenes y Reconocimiento de Patrones Lún. Decano Facultad de Ingeniería, Universidad de Ibagué. manuel.forero@unibague.edu.co.
- **Sergio Luis Alejandro Miranda Rojas:** Ing. Electrónico, estudiante de Maestría en Ingeniería de Control. Asistente graduado, Universidad de Ibagué. Miembro semillero en Procesamiento de Imágenes y Reconocimiento de Patrones Lún. sergio.miranda@unibague.edu.co.

---

Los puntos de vista expresados en este artículo no reflejan necesariamente la opinión de la Asociación Colombiana de Facultades de Ingeniería.

Copyright © 2020 Asociación Colombiana de Facultades de Ingeniería (ACOFI)