

Supresión de ruido Riciano en imágenes de resonancia magnética del cerebro utilizando un algoritmo de promedio local y global

Sergio Eduardo Páez Aguilar¹, Dante Mújica-Vargas¹,
Jean Marie Vianney Kinani²

¹ CENIDET, Departamento de Ciencias de la Computación,
Cuernavaca, Morelos,
México

² ITESHU, Departamento de Sistemas Computacionales,
Huichapan, Hidalgo, Mexico

{sergio.paez,dantemv}@cenidet.edu.mx

Resumen. La imagen de resonancia magnética es el estudio más utilizado para diagnosticar enfermedades cerebrales; sin embargo, su calidad visual es severamente degradada por ruido Riciano que se incorpora inevitablemente durante el proceso de adquisición. Para atender este problema, en la literatura se tiene como un referente importante algoritmo, Non-Local Means, sin embargo, éste tiene un costo computacional alto, aunado a que en realidad solo utiliza información local de las imágenes. Por lo cual, en este trabajo de investigación se propone modificar el algoritmo original para minimizar su tiempo de ejecución y cumplir con el uso de la redundancia de información mediante el uso de promedios local y global.

Palabras clave: ruido Riciano, imágenes de resonancia magnética del cerebro, promedio local y global.

Rician Noise Suppression on Brain Magnetic Resonance Images by Using a Local-Global Means Algorithm

Abstract. Magnetic resonance imaging is the most widely used study to diagnose brain diseases; however, its visual quality is severely degraded by Rician noise that is inevitably incorporated during the acquisition process. To address this problem, in the literature there is an important reference algorithm *Non-Local Means*, however, it has a high computational cost, in addition to actually only using local information of the images. Therefore, in this research paper it is proposed to modify the original algorithm to minimize its runtime and comply with the use of information redundancy by using local and global averages.

Keywords: Rician noise, magnetic resonance imaging, local and global averages.

1. Introducción

La imagen de resonancia magnética (IRM), es una notable técnica no invasiva, que permite crear imágenes de la anatomía del cuerpo humano en cualquier proyección sin mover al paciente. Esta es la técnica más utilizada para diagnosticar enfermedades cerebrales, ya que proporciona información detallada de los tejidos sanos, así como posibles alteraciones fisiológicas y patológicas [10]. La calidad visual de esta imagen desempeña un papel fundamental en la precisión del análisis clínico; sin embargo, se puede ver severamente degradada por ruido. En la actualidad aunque la tecnología del resonador magnético ha aumentado notablemente, la IRM sigue siendo afectada por el ruido, este se incorpora inevitablemente durante el proceso de adquisición. El ruido no solo afecta al diagnóstico clínico, si no también tareas como segmentación, reconocimiento y análisis computarizado automático [8].

Para mejorar la calidad visual de la IRM existen dos caminos uno de ellos es ajustar los parámetros del resonador magnético de manera que se obtenga una mejor Relación Señal-Ruido Pico (PSNR); sin embargo, esta solución trae como consecuencia el aumento en el tiempo de adquisición causando molestia al paciente. El otro camino es disminuir el ruido utilizando algoritmos de visión artificial. En el estado del arte se pueden encontrar técnicas de filtrado de ruido en IRM del cerebro, a continuación se mencionan algunas de ellas: En [11], se utilizó la prueba de Kolmogorov Smirnov como prueba estadística, para encontrar vectores de similitud entre píxeles de una IRM, con los cuales se realizó un promedio para mejorar la calidad visual de la imagen. Por otra parte, en [6] se trabajó con el algoritmo de promediado no local y la teoría GRIS, esta teoría consiste en ver una IRM como un sistema incompletamente definido, un sistema contiene información de dos tipos, completamente conocida (Blanco) y desconocida (Negro). A partir del sistema GRIS se plantea completar la información.

En una IRM se denota Blanco a la información que forma parte real de la imagen y Negro al ruido, partiendo del sistema GRIS se plantea mejorar la calidad visual. En [3], se introdujo el algoritmo de Promedio No-Local (*Non-Local Means*), su concepto de tomar en cuenta la información redundante dentro de la imagen ha conseguido tener un equilibrio entre la buena calidad y la conservación de las estructuras finas de una imagen, sin embargo, el costo computacional de este filtro es alto, aún cuando se trabaja con imágenes de poca dimensión, ya que se deben tomar en cuenta todos los píxeles de la imagen. En [7], se utilizó el algoritmo *Non-Local Means* (NLM) con un apropiado criterio de agrupación difusa, para suprimir ruido en IRM. En [1], se utilizó un filtro Laplaciano, en conjunto con un algoritmo NLM. Para acelerar el proceso de filtrado, se implementó una búsqueda de parches de similaridad para garantizar un valor adecuado para el píxel que se procesa. En [1, 9] se analizaron en conjunto 23 filtros para suprimir ruido en IRM entre ellos se utilizaron, el algoritmo de promedio no local, filtro bilateral, transformación por wavelets, transformación por curvelets, filtros estadísticos, entre otros.

Cada uno de los filtros que se han utilizado tiene sus ventajas y desventajas mencionadas en sus respectivos textos. Sin embargo, en cada uno de los textos se puede observar que aún existen deficiencias, si se logra una alta calidad cuantitativa las estructuras finas de la imagen son afectadas, si se logra conservar los detalles finos se obtiene una baja calidad cuantitativa. El filtro más sobresaliente es el NLM, tiene un rendimiento bastante alto; sin embargo, el costo computacional también es alto, aún cuando se trabaja con imágenes de tamaños pequeños, ya que se deben tomar en cuenta todos los píxeles de la imagen. Para obtener un equilibrio entre el costo computacional, la buena calidad y la conservación de las estructuras finas de la imagen, en este texto se propone una modificación al algoritmo (*Non-Local Means*). El método propuesto se nombró Algoritmo de Promedio Local y Global.

El resto de este texto se divide de la siguiente manera. En la Sección 2 se presenta un resumen conceptual requerido para el entendimiento de este trabajo; posteriormente, en la Sección 3 se detalla la metodología que se propone. Los resultados obtenidos con este algoritmo son presentados en la Sección 3 y finalmente, las Conclusiones son presentadas en la Sección 4.

2. Información contextual

2.1. Ruido Riciano

Los datos obtenidos durante la adquisición de una IRM son valores complejos que representan la transformada de Fourier de una distribución de magnetización de un volumen en un tejido. Una transformada de Fourier inversa convierte estos datos adquiridos en magnitudes y frecuencias que representan las principales características psicológicas y morfológicas de la persona que se realiza el estudio. El ruido en una IRM data de cada inductor, se asume que el ruido es un proceso Gaussiano no correlacionado con media 0 y con igual varianza en ambas partes real e imaginaria debido a la linealidad y ortogonalidad de la transformada de Fourier [8].

El cálculo computacional de una imagen de magnitud es una operación no lineal, la función de densidad de la probabilidad (PDF) de los datos en una IRM cambia según el resonador magnético. En resonadores magnéticos que cuentan con un solo inductor, la magnitud de los datos en el dominio espacial se modela con una distribución de Rician, por esta razón la perturbación que se genera se nombra ruido Riciano. Este ruido representa el error entre la intensidad de la imagen y la verdadera medición de los datos [8]. Por su naturaleza, el ruido es localmente dependiente de las señal. En la ecuación (1) se describe la distribución Riciana:

$$p_M(M|A, \sigma_n) = \frac{M}{\sigma_n^2} \exp^{-(M^2+A^2)/2\sigma_n^2} I_0\left(\frac{AM}{\sigma_n^2}\right) u(M), \quad (1)$$

donde $I_0(\cdot)$ es la función de Bessel modificada de primera clase de orden cero, σ_n^2 es la varianza del ruido, A el nivel de la señal sin ruido, M la magnitud

variable de la resonancia magnética y $u(\cdot)$ es la función escalón de Heaviside. En alta SNR, es decir, en regiones de alta intensidad (brillo) de la magnitud de la imagen, la distribución Riciana tiende a una distribución Gaussiana con una media $\sqrt{A^2 + \sigma_n^2}$ y varianza σ_n^2 tal como lo muestra la ecuación (2):

$$p_M(M|A, \sigma_n) = \frac{1}{\sqrt{2\pi}\sigma_n^2} \exp^{-(M^2 + \sqrt{A^2 - \sigma_n^2})/2\sigma_n^2} u(M). \quad (2)$$

En el fondo de la imagen, donde la SNR es cero debido a la falta de densidad de los protones de agua en el aire, la PDF Riciana se simplifica a una distribución de Rayleigh como se muestra en la ecuación (3), con una PDF:

$$p_M(M, \sigma_n) = \frac{M}{\sigma_n^2} \exp^{-M^2/2\sigma_n^2} u(M). \quad (3)$$

Las MRI adquiridas utilizando imágenes paralelas con sistemas de múltiples bobinas, el ruido es altamente no homogéneo (inhomogéneo). La señal adquirida en el dominio espacial complejo en cada bobina también puede ser modelada como la señal original corrompida con ruido complejo aditivo Gaussiano, con media cero y varianza igual a σ_n^2 . Si no se realiza un sub-muestreo en el k -ésimo espacio, la imagen de magnitud compuesta puede obtenerse utilizando métodos tales como la suma de cuadrados (SOS) [4]. Suponiendo que los componentes de ruido son independientes e idénticamente distribuidos (*iid*), sobre la magnitud de la señal $M_L(x)$, esta seguirá una distribución Chi no central como se muestra en la ecuación (4), con PDF [4]:

$$p_{M_L}(M_L|A_L, \sigma_n, L) = \frac{A_L^{1-L}}{\sigma_n^2} M_L^L \exp^{-(M_L^2 + A_L^2)/2\sigma_n^2} I_{L-1} \left(\frac{A_L M_L}{\sigma_n^2} \right) u(M_L), \quad (4)$$

donde L es el número de bobinas. La ecuación (4) se reduce a una distribución Riciana cuando $L = 1$. En el fondo, este PDF se reduce a una distribución Chi central como se muestra en la ecuación (5), con PDF:

$$p_{M_L}(M_L|\sigma_n, L) = \frac{2^{1-L}}{\Gamma(L)} \frac{M_L^{2L-1}}{\sigma_n^{2L}} \exp^{-M_L^2/2\sigma_n^2} u(M_L). \quad (5)$$

La ecuación (5) se convierte en Rayleigh cuando $L = 1$. Este modelo estadístico es el modelo usual para la magnitud de la señal en la fase de arreglo de las bobinas y para imágenes en paralelo asumiendo que no se realiza ningún submuestreo de los datos en el k -ésimo espacio para cada bobina.

2.2. Non-Local Means

El filtro *Non-Local Means* es una variación más compleja del filtro *K-Nearest Neighbors* [5].

En este sentido, se puede definir como vecindad de un píxel x cualquier conjunto de píxeles y en la imagen, de modo que una ventana alrededor de y

se asemeje a una ventana alrededor de x . Todos los píxeles en esa vecindad se pueden usar para predecir una mejor estimación de x . El hecho de que exista tal auto-similitud es una suposición de regularidad, en realidad más general y más precisa que todas las suposiciones de regularidad que consideramos al tratar con filtros de suavizado locales, y también generaliza una suposición de periodicidad de la imagen.

Dado v ser la observación de la imagen ruidosa definida en un dominio delimitado $\Omega \subset \mathbb{R}^2$ y dado $x \in \Omega$. El filtro *Non-Local Means* estima el valor de x como un promedio de valores de todos los píxeles cuya vecindad gaussiana sea parecida a la vecindad de x [3], ver ecuación (6):

$$NL(v)(x) = \frac{1}{C(x)} \int_{\Omega} \exp - \frac{\left(G_a * |v(x + \cdot) - v(y + \cdot)|^2 \right)_{(0)}}{h^2} v(y) dy, \quad (6)$$

donde G_a es un kernel gaussiano con desviación estándar a , h actúa como un parámetro del filtro, y $C(x) = \int_{\Omega} \exp - \frac{\left(G_a * |v(x + \cdot) - v(z + \cdot)|^2 \right)_{(0)}}{h^2} dz$ es un factor normalizante. Debe considerarse mediante la ecuación (7) que:

$$\left(G_a * |v(x + \cdot) - v(y + \cdot)|^2 \right)_{(0)} = \int_{\mathbb{R}^2} G_a(t) |v(x + t) - v(y + t)|^2 dt. \quad (7)$$

La versión en el dominio discreto de este filtro, fue introducida por [3], al hacer la siguiente consideración. Dada una imagen con ruido $u = \{u(i) | i \in I\}$, el valor estimado para un pixel i , es obtenido a través del promedio de to dos los píxeles en la imagen que tengan una intensidad similar, el funcionamiento del algoritmo se describe en la ecuación (8):

$$NL[u](i) = \sum_{j \in I} w(i, j) \cdot u(j), \quad (8)$$

donde los pesos $w(i, j)$ dependen de la similaridad entre el i -ésimo y el j -ésimo pixel, satisfaciendo las siguientes condiciones: $0 \leq w(i, j) \leq 1$ y $\sum_{j \in I} w(i, j) = 1$. La similaridad entre los píxeles se determina mediante la intensidad de los píxeles [2], a partir de la distancia euclidiana, por lo tanto los píxeles considerados similares tendrán un mayor peso al realizar el promediado, y los considerados disimilares un peso menor [2]. El algoritmo de promediado no local se encuentra descrito en pseudocódigo en el Algoritmo 1.

El concepto de tomar en cuenta todos los píxeles de una imagen se traduce en un costo computacional alto, para solucionar este conflicto Antoni Buades sugirió introducir un radio de búsqueda de píxeles similares, en el estado del arte se encuentran diferentes radios (3x3, 6x6 y 9x9) [3]. De esta forma se reduce notablemente el costo computacional; sin embargo, el concepto de promediado no local no se cumple y la calidad de las imágenes resultantes es menor en comparación con la versión original del algoritmo. Una manera de solventar el

Algoritmo 1: *Non-Local Means*

Entrada: $v[], h$
Salida: $u[]$

```

1 per  $i \leftarrow 0$  to  $N$  fai
2    $v(N_i)$ 
3    $z \leftarrow 0$ 
4    $sumw \leftarrow 0$ 
5   per  $j \leftarrow 0$  to  $N$  fai
6      $v(N_j)$ 
7      $w \leftarrow e^{\frac{-\|v(N_i)-v(N_j)\|_{2,\alpha}^2}{h*h}}$ 
8      $sumw \leftarrow sumw + w * v(j)$ 
9      $z \leftarrow z + w$ 
10     $u(i) \leftarrow \frac{sumw}{z}$ 
11 devolver  $u[]$ 

```

costo computacional es paralelizando el algoritmo, CUDA es una arquitectura de cálculo paralelo de NVIDIA que aprovecha la potencia de una unidad de procesamiento gráfico para proporcionar un incremento del rendimiento del sistema. En este trabajo; en primera instancia, se paralelizó el algoritmo de promedio no local con una tarjeta gráfica NVIDIA GT 710 con 192 núcleos CUDA. Sin embargo, no todos los equipos cuentan con la arquitectura necesaria para poder paralelizar los algoritmos. Para solventar el costo computacional, sin ajustarse al hardware del equipo, se propone una modificación al algoritmo de promediado no local de manera que se tomen en cuenta todos los pixeles similares de la imagen y al mismo tiempo se obtenga un equilibrio entre el costo computacional y el objetivo del filtrado de ruido, este algoritmo se nombró algoritmos de promedio local y global.

3. Metodología propuesta

El fundamento del algoritmo de promedio local y global se basa en utilizar la redundancia en toda la imagen, considerando tanto los pixeles vecinos con intensidades similares, así como las diferentes regiones dentro de la imagen que compartan un grado de similaridad con la región que está siendo procesada (ver Figura 1). Para obtener regiones con la misma dimensión y con la finalidad de no limitar el tamaño de la imagen con la que se trabaja se propone utilizar 100 regiones, creando una especie de malla de 10 columnas y 10 filas. Para este trabajo se utilizaron imágenes con una dimensión de 320x240 pixeles; por lo tanto cada región tiene una dimensión de 32x24 pixeles. Una vez dividida la imagen se obtiene el pixel más representativo de cada región, se propone utilizar la **moda estadística** M_o , ya que es el dato con mayor frecuencia de ocurrencia.

Una vez que se tiene el vector de representantes de cada región $u(r)$, se elige un pixel i a procesar, para dicho pixel se busca en el vector de representantes

$u(r)$ píxeles similares, esta similaridad se mide en la intensidad en niveles de gris a través de la distancia euclidiana. Para un píxel i se activan n cantidad de regiones dependiendo de la similaridad. Cuando se tienen las n regiones se realiza el promediado tomando en cuenta la intensidad de cada uno de los píxeles que se encuentren dentro de las regiones activadas, tanto en la región local (región a la que pertenece el píxel a procesar) como en las regiones globales que se han activado de acuerdo al vector de similitud.

Dos aspectos importantes que deben ser tomados en cuenta en este método es el fondo de la imagen y el traslapamiento de regiones, cuando el píxel i a procesar tiene valor cercano al negro, es decir intensidad cercana al 0, se activarán las n regiones que corresponden al fondo de la imagen, para descartar el fondo se utilizó la desviación estándar $\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$, puesto que es una medida de dispersión. Por lo tanto si el representante de una región es un valor cercano a 0, se debe medir su dispersión para saber si contiene una región de interés, si la dispersión es menor a 0.25 se considerará fondo de la imagen y se procederá a clasificarla como disimilar, la ganancia de tomar en cuenta esta región es nula. Para este texto se tomo 0.25 como umbral para la dispersión debido a que representa la cuarta parte de una región, es decir, 192 píxeles. Si baja el umbral y se toma en cuenta una dispersión menor la calidad de la imagen se verá afectada notablemente según las pruebas realizadas. El segundo factor a considerar es el traslapamiento de regiones, durante las pruebas se encontraron regiones de píxeles que contenían un 60 % fondo y 40 % región de interés, por lo que se debe tomar en cuenta en el vector de similitud ya que dependiendo de la imagen puede ser una región de suma importancia para el contenido de la imagen, tomando en cuenta que en el calculo de la moda se tomará unicamente el primer valor que se encuentre como de mayor ocurrencia solo se tomará en cuenta un valor, el primero que se encuentre.

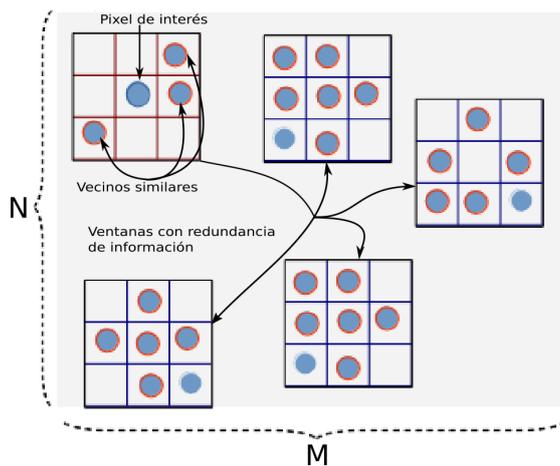


Fig. 1. Metodología propuesta.

Dentro de las pruebas se encontraron regiones donde la moda fue un valor de 4 con una frecuencia de ocurrencia 305, pero en la misma región se presentaba un valor 225 con una frecuencia de ocurrencia 276, bien podría ser un candidato a ser representante y esto representa un traslapamiento de regiones.

Por lo tanto se debe realizar una segunda inspección si la desviación estándar es mayor a 0.25 se debe tomar en cuenta en el vector de similaridad. El no tomar en cuenta estos dos aspectos provoca artefactos en la imagen y por consecuencia su calidad disminuye notablemente. El algoritmo de promedio local y global se encuentra resumido en el Algoritmo 2.

Algoritmo 2: *Local-Global Means*

Entrada: $v[], h$
Salida: $u[]$

```

1  $n \leftarrow 10$ 
2  $C \leftarrow \frac{columns}{n}$ 
3  $F \leftarrow \frac{rows}{n}$ 
4  $grid \leftarrow 1$ 
5 per  $k \leftarrow 0$  to  $n$  fai
6   per  $l \leftarrow 0$  to  $n$  fai
7      $Mode[grid] \leftarrow M_o(region)$ 
8      $DevStd[grid] \leftarrow \sigma(region)$ 
9     per  $ii \leftarrow 0$  to  $N$  fai
10       $v(N_{ii})$ 
11      per  $jj \leftarrow 0$  to  $N$  fai
12         $M_o(N_{jj})$ 
13         $x \leftarrow e^{\frac{-\|v(N_{ii}) - M_o(N_{jj})\|_{2,\alpha}^2}{h * h}}$ 
14      per  $i \leftarrow 0$  to  $N$  fai
15         $v(N_i)$ 
16         $z \leftarrow 0$ 
17         $sumw \leftarrow 0$ 
18        per  $j \leftarrow 0$  to  $N$  fai
19           $v(N_j)$ 
20           $w \leftarrow e^{\frac{-\|v(N_i) - v(N_j)\|_{2,\alpha}^2}{h * h}}$ 
21           $sumw \leftarrow sumw + w * v(j)$ 
22           $z \leftarrow z + w$ 
23           $u(i) \leftarrow \frac{sumw}{z}$ 
24 devolver  $u[]$ 

```

4. Resultados

4.1. Métricas

Para evaluar objetivamente la calidad de la supresión del ruido riciano en imágenes de resonancia magnética, se consideran cuatro aspectos. El primero, está relacionado con el rendimiento de la supresión de ruido y se evalúa utilizando la Relación Señal-Ruido Pico (PSNR) [9], ver ecuación (9). El segundo es cuantificar la preservación de los detalles finos de la imagen restaurada, está determinada por el error absoluto medio (MAE) [9], ver ecuación (11). El tercero, es el Índice de Similitud Estructural (SSIM) [13], ver ecuación (12), es una medida cuantitativa de la diferencia entre la imagen original y reconstruida en cuanto a sus luminancias, contrastes e información de estructura. Matemáticamente, estas tres métricas están dadas por los siguientes expresiones:

$$PSNR = 10 \cdot \log \left[\frac{(\text{máx}(x(i, j)))^2}{MSE} \right], \quad (9)$$

donde MSE es el Error Cuadrático Medio y es determinado mediante la ecuación (10):

$$MSE = \frac{1}{M \cdot N} \sum_{i=1}^M \sum_{j=1}^N [x(i, j) - \hat{e}(i, j)]^2, \quad (10)$$

donde $M \cdot N$ representa el tamaño de las imágenes que se están analizando, $x(i, j)$ es la imagen original y $\hat{e}(i, j)$ es la imagen restaurada o filtrada. Por su parte MAE es calculada a partir de:

$$MAE = \frac{1}{M \cdot N} \sum_{i=1}^M \sum_{j=1}^N |x(i, j) - \hat{e}(i, j)|, \quad (11)$$

La métrica SSIM en una forma simplificada es calculada mediante la siguiente expresión:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1) \cdot (2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1) \cdot (\sigma_x^2 + \sigma_y^2 + C_2)}, \quad (12)$$

donde x es la imagen original, y es la imagen restaurada, μ_x y μ_y son los valores de la luminancia, σ_x y σ_y son los valores de contraste, C_1 y C_2 son dos parámetros constantes. Finalmente, el último aspecto que se consideró fue el tiempo de ejecución, con unidades de segundos.

4.2. Evaluaciones cuantitativa y cualitativa

Con la finalidad de verificar el rendimiento del método propuesto y verificar su eficiencia contra otros métodos, se utilizaron 50 imágenes de resonancia magnética ($T1$) obtenidas a partir del simulador *BrainWeb* [3], se degradaron con diferentes densidades de ruido Riciano 5%, 10%, 15%, 20%, 25% y

30 % utilizando el generador de ruido presentado en [12]. Cada imagen tiene una dimensión de 320x240 pixeles. Los métodos evaluados en este trabajo de investigación fueron *Local-Global Means* (método propuesto, LGM), así como Promediado *Non-Local Means* (NLM), *Parallel Non-Local Means* (PNLM) y el *Bilateral Filter with Optimal Parameters* (BPO).

Un resumen de los métricas evaluados en este trabajo de investigación es presentado en la Tabla 1. Cabe resaltar que el desempeño de todos los métodos se considera equiparable; sin embargo, fue con el método propuesto que se obtuvo valor más alto en la relación señal a ruido pico para todas las densidades de ruido y un menor valor en las métricas error absoluto medio y similitud estructural, en cuanto al tiempo fue aproximado a la versión paralela del algoritmo de referencia. Por otra parte, en la Figura 2, se presenta la tendencia gráfica de estos resultados.

Tabla 1. Resultados cuantitativos.

Densidad de ruido	Algoritmo	PSNR (dB)	MAE	SSIM	Tiempo (ms)
5 %	BPO	37.3009	0.9758	0.8915	9.55
	NLM	40.8252	0.6928	0.9712	182.21
	PNLM	41.6243	0.6167	0.9771	18.12
	LGM	43.4741	0.5361	0.9781	22.31
10 %	BPO	35.5955	1.0860	0.8694	9.47
	NLM	36.6438	0.9821	0.9612	185.19
	PNLM	38.5421	0.8567	0.9701	18.22
	LGM	38.9105	0.8269	0.9719	22.29
15 %	BPO	33.1096	1.3906	0.8553	9.42
	NLM	33.7458	1.3642	0.9007	182.16
	PNLM	35.1202	1.0896	0.9586	18.19
	LGM	35.7901	1.0835	0.9694	22.21
20 %	BPO	30.5459	1.7229	0.8001	9.44
	NLM	31.9605	1.6336	0.8397	184.66
	PNLM	32.0712	1.3875	0.8814	18.36
	LGM	33.7426	1.3653	0.8997	22.37
25 %	BPO	27.8119	1.9229	0.7862	9.47
	NLM	30.4286	1.7038	0.8054	185.76
	PNLM	32.0111	1.3915	0.8800	18.36
	LGM	32.2369	1.3805	0.8896	22.43
30 %	BPO	25.5047	2.0302	0.6304	9.56
	NLM	29.1481	1.7488	0.8071	195.41
	PNLM	30.5221	1.7107	0.8201	18.50
	LGM	30.8436	1.7000	0.8265	22.47

Finalmente, una evaluación subjetiva se puede hacer a partir de las imágenes presentadas en la Figura 3. En este sentido, se debe hacer mención que todos los algoritmos evaluados en este experimento están basados en el cálculo del valor medio, por lo cual las imágenes restauradas presentan un suavizado en las regiones que la conforman (materias gris y blanca, así como el fluido cerebroes-

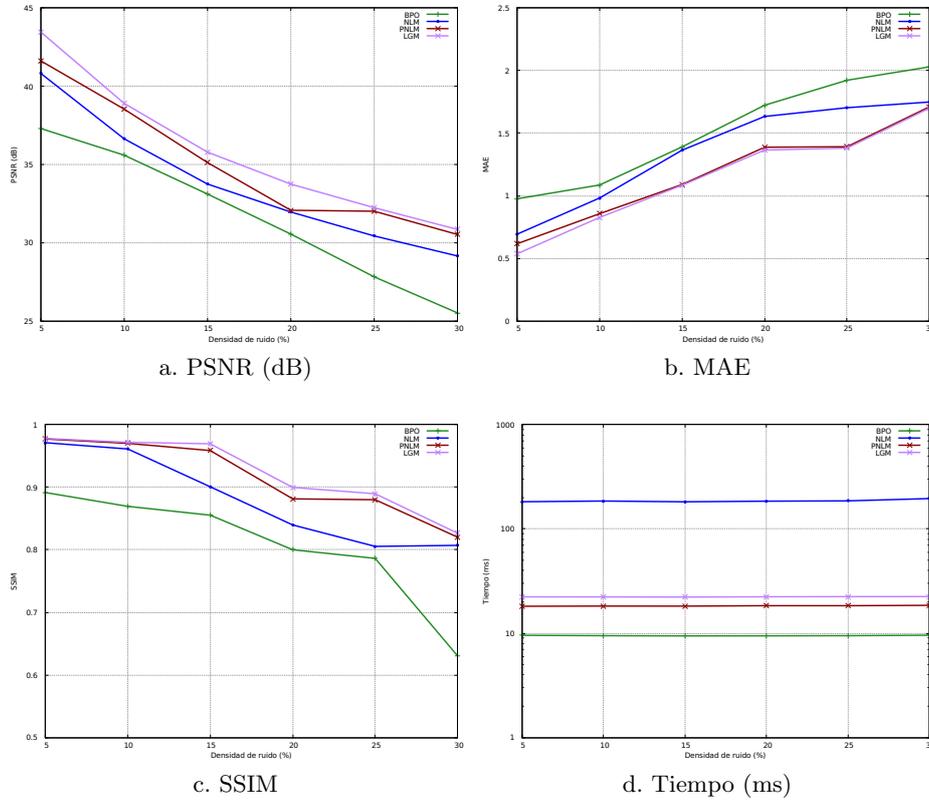


Fig. 2. Representación gráfica de los resultados cuantitativos.

pinal). El impacto directo es en los bordes o fronteras de dichas regiones, ya que no están delimitadas como debía de esperarse. Es bien sabido que todo filtro debe hacer dos tareas en forma simultanea, suprimir dentro de sus posibilidades el ruido y no destruir los detalles finos de las imágenes (algo que reside en las fronteras de las regiones).

Si esta condición no se da, entonces se puede limitar la segmentación de dichas regiones si se quiere hacer ese procesamiento posteriormente. Una solución puede ser una fase de interpolación que permita incrementar la nitidez de las fronteras y la vez la homogeneizar aún más las regiones.

5. Conclusiones

En este trabajo propuso un heurística para mejorar el rendimiento y tiempo de ejecución del algoritmo *Non-Local Means* para la tarea de supresión de ruido Riciano en imágenes de resonancia magnética del cerebro. Básicamente, ésta

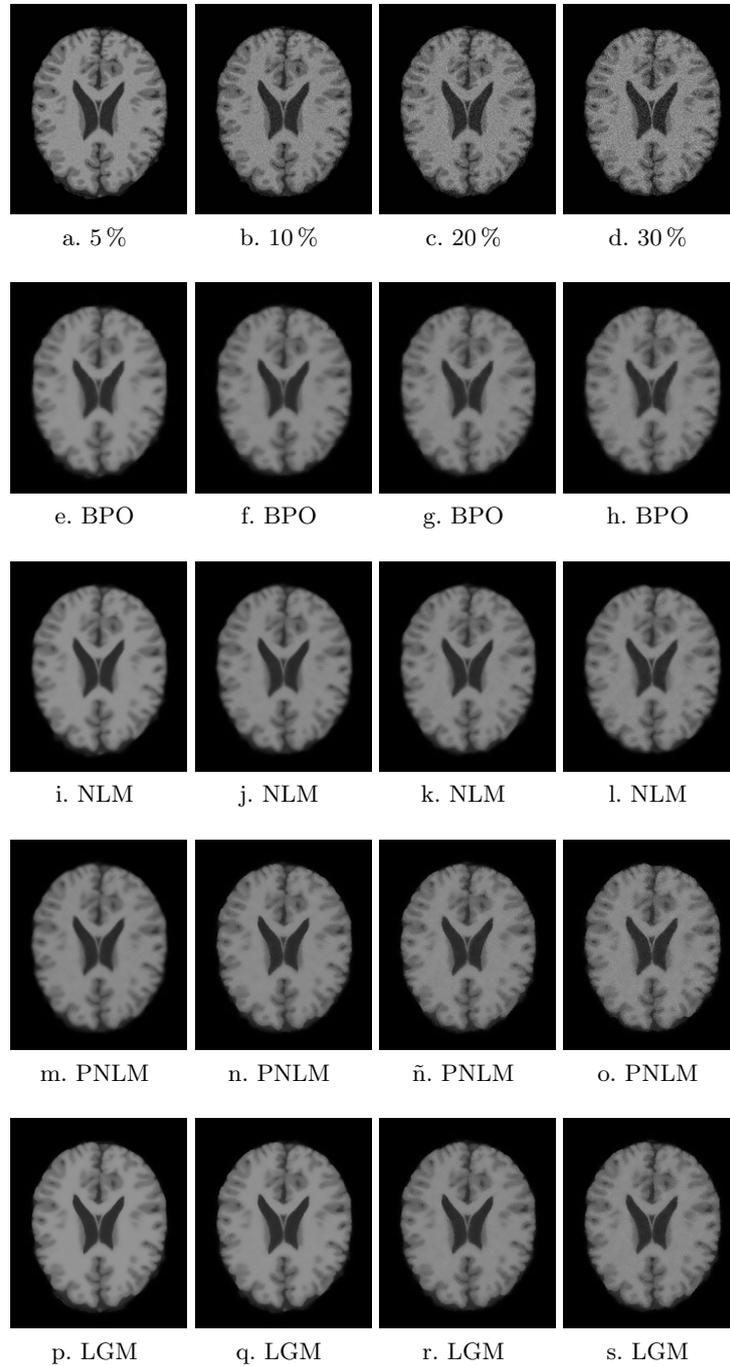


Fig. 3. Evaluación subjetiva.

consiste en el uso de la redundancia de información tanto local como globalmente. La experimentación permitió evaluar el desempeño de la modificación sugerida, resaltándose una reducción del costo computacional en un 90 % en comparación con el algoritmo convencional y un aumento de entre 2 y 3 dBs en la relación señal a ruido pico. Como trabajo futuro se espera hacer el número de mallas en las que se trabajan se ajusten adaptativamente en número y en tamaño, en función de las imágenes de entrada.

Agradecimientos. Los autores están agradecidos con los revisores por sus valiosos comentarios y sugerencias perspicaces, que ayudaron a mejorar esta investigación de manera significativa. También, agradecen al CONACYT, así como al TecNM/CENI- DET por su apoyo financiero a través del proyecto 5688.16-P llamado "Sistema para procesamiento de imágenes de resonancia magnética para segmentación 3D y visualización de tejidos cerebrales".

Referencias

1. Bhujle, H.V., Chaudhuri, S.: Laplacian based non-local means denoising of MR images with Rician noise. *Magnetic resonance imaging* 31(9), 1599–1610 (2013)
2. Bovik, A.C.: *The essential guide to image processing*. Academic Press (2009)
3. Buades, A., Coll, B., Morel, J.M.: A review of image denoising algorithms, with a new one. *Multiscale Modeling & Simulation* 4(2), 490–530 (2005)
4. Constantinides, C.D., Atalar, E., McVeigh, E.R.: Signal-to-noise measurements in magnitude images from NMR phased arrays. *Magnetic Resonance in Medicine* 38(5), 852–857 (1997)
5. Kharlamov, A., Podlozhnyuk, V.: *Image denoising*. NVIDIA (2007)
6. Li, H., Suen, C.Y.: A novel non-local means image denoising method based on grey theory. *Pattern Recognition* 49, 237–248 (2016)
7. Liu, B., Sang, X., Xing, S., Wang, B.: Noise suppression in brain magnetic resonance imaging based on non-local means filter and fuzzy cluster. *Optik-International Journal for Light and Electron Optics* 126(21), 2955–2959 (2015)
8. Mohan, J., Krishnaveni, V., Guo, Y.: A survey on the magnetic resonance image denoising methods. *Biomedical Signal Processing and Control* 9, 56–69 (2014)
9. Mújica-Vargas, D., de Jesús Rubio, J., Kinani, J.M.V., Gallegos-Funes, F.J.: An efficient nonlinear approach for removing fixed-value impulse noise from grayscale images. *Journal of Real-Time Image Processing* 14(3), 617–633 (2018)
10. Oleaga, L., Lafuente, J.: *Aprendiendo los fundamentos de la resonancia magnética*. Madrid: Buenos Aires (2007)
11. Rajan, J., Arnold, J., Sijbers, J.: A new non-local maximum likelihood estimation method for Rician noise reduction in magnetic resonance images using the Kolmogorov–Smirnov test. *Signal processing* 103, 16–23 (2014)
12. Ridgway, G.: Rice/Rician distribution. <https://www.mathworks.com/matlabcentral/fileexchange/14237-rice-rician-distribution?focused=5109004&tab=example> (2008 (accessed May 13, 2018))
13. Wang, Z., Simoncelli, E.P., Bovik, A.C.: Multiscale structural similarity for image quality assessment. In: *Signals, Systems and Computers, 2004. Conference Record of the Thirty-Seventh Asilomar Conference on*. vol. 2, pp. 1398–1402. IEEE (2003)