

## Supresión de Ruido Riciano en Imágenes de Resonancia Magnética

Virna Viridiana Vela Rincón<sup>1</sup>, Dante Mújica Vargas<sup>2</sup>, Yuridia Mújica Vargas<sup>3</sup>

<sup>1,2</sup> *Departamento de Ciencias Computacionales, Centro Nacional de Investigación y Desarrollo Tecnológico,*

<sup>3</sup> *Subdirección de Prevención y Protección a la Salud, Dirección Médica-ISSSTE,*

*Interior Internado Palmira S/N, Col. Palmira, Cuernavaca, Morelos, México, viryvela@cenidet.edu.mx,*

*dantemv@cenidet.edu.mx, ymujica@issste.gob.mx*

**Resumen**— Una condición inherente en las imágenes digitales es la presencia del ruido; este se incorpora cuando las imágenes digitales son generadas o durante su proceso de transmisión y recepción. La supresión de ruido es la tarea de procesamiento digital de imágenes considerada la más antigua. En la literatura se han presentado diferentes métodos para suprimir ruido impulsivo, multiplicativo y aditivo; sin embargo, un método universal para suprimir todos los tipos de ruido en cualquier tipo de imágenes no ha sido presentado en el estado del arte. Independientemente de la implementación, todos los métodos tienen el mismo objetivo en común: remover el ruido sin destruir los detalles finos de las imágenes. Este documento presenta el desarrollo, implementación y evaluación de tres algoritmos para suprimir ruido riciano de imágenes de resonancia magnética; específicamente los filtros: *K-Nearest Neighbors*, *Non-Local Means* y *Fast Non-Local Means*. Utilizando una Unidad de Procesamiento Gráfico (GPU).

**Abstract**— An inherent condition in digital images is the presence of noise; this is incorporated when the digital images are generated or during the process of transmission and reception. The suppression of noise is the task of digital image processing considered to be the oldest. In the literature, different methods have been presented to suppress impulsive, multiplicative and additive noise; however, a universal method to suppress all types of noise in any type of images has not been presented in the state of the art. Regardless of the implementation, all the methods have the same common goal: to remove the noise without destroying the fine details of the images. This document presents the development, implementation and evaluation of three algorithms to suppress rician noise from magnetic resonance images; namely: *K-Nearest Neighbors*, *Non-Local Means* and *Fast Non-Local Means* filters. Using a Graphic Processing Unit (GPU).

**Palabras clave** — Fast Non-Local Means, GPU, K-Nearest Neighbors, MRI, Non-Local Means

### I. INTRODUCCIÓN

En los últimos años la relación señal ruido y la velocidad de adquisición en una imagen de resonancia magnética (MRI, con sus siglas en inglés) continúa siendo afectada por artefactos y ruido, a pesar que se ha incrementado la resolución de las imágenes. Con el propósito de mejorar el contenido de la imagen, que es relevante para el diagnóstico clínico, debe realizarse una compensación entre la reducción de ruido y la preservación de características o detalles de interés [24]. Sin

embargo, la reducción de ruido continúa siendo una tarea difícil. Una variedad de técnicas han sido presentadas en la literatura: estimación de máxima verosimilitud no local [10], algoritmo iterativo [14], difusión anisotrópica [17], [18], filtro bilateral [21], entre otras [7], [24], [19], [20], [27]; y cada una de estas técnicas tiene sus propias ventajas y limitaciones. Existen investigaciones donde los filtros de supresión de ruido han sido comparados exclusivamente para imágenes de resonancia magnética bajo las mismas condiciones, además se han propuesto diferentes modificaciones a estos algoritmos, especialmente el algoritmo NLM [11]-[13], [15], [16], [22], [23], [25], [26], [28].

La búsqueda de métodos eficaces para suprimir ruido en imágenes continúa siendo un desafío válido, a pesar de la sofisticación de los métodos propuestos recientemente, la mayoría de los algoritmos aún no han alcanzado un nivel deseable de aplicabilidad [25].

El propósito de este artículo es presentar una evaluación de tres algoritmos para suprimir ruido riciano en imágenes de resonancia magnética; específicamente los filtros: *K-Nearest Neighbors*, *Non-Local Means* y *Fast Non-Local Means*, utilizando una Unidad de Procesamiento Gráfico (GPU).

### II. MATERIALES Y MÉTODOS

La idea principal de cualquier filtro que utilice información ya sea local o global es calcular el peso de los píxeles según cuán similares sean sus intensidades o bien sus colores. Los tres métodos considerados para suprimir ruido riciano de imágenes de resonancia magnética son los filtros *K-Nearest Neighbors*, *Non-Local Means* y *Fast Non-Local Means* [1, 2].

#### A. *K-Nearest Neighbors*

El filtro *K-Nearest Neighbors* o *sigma* fue introducido para reducir el ruido aditivo blanco [3]:

$$v(x) = u(x) + n(x) \quad (1)$$

donde  $x$  indica la posición de los píxeles,  $v(x)$  es la intensidad del ruido,  $u(x)$  es el valor verdadero en el píxel  $x$  y  $n(x)$  es la perturbación de ruido. Cuando los valores de ruido  $n(x)$  y  $n(y)$  en diferentes píxeles son asumidos a ser variables aleatorias independientes e independientes del valor de imagen  $u(x)$ , se dice que el ruido es blanco. En general, se supone que  $n(x)$  sigue una distribución gaussiana con  $\mu = 0$  y  $\sigma > 0$ .

El filtro sigma y de vecinos cercanos fueron propuestos originalmente como un promedio de los píxeles espacialmente cercanos con una diferencia de nivel de gris inferior a un cierto umbral  $h$ . Por lo tanto, para un cierto píxel  $x$ , el valor de eliminación es el promedio de píxeles en el vecindario espacial e intensidad:

$$y \in \Omega | |x - y| | < \rho \wedge |u(x) - u(y)| < h \quad (2)$$

Sin embargo, para hacer coherente con extensiones adicionales y facilitar el desarrollo matemático, se escribe el filtro en un marco continuo en una forma de promedio ponderado. Se denota el filtro de  $k$  vecinos cercanos o sigma por NF y se definirá para un píxel  $x$  como:

$$NF_{h,\rho}u(x) = \frac{1}{C(x)} \int_{B\rho(x)} u(y) \exp \frac{-|u(y)-u(x)|^2}{h^2} dy \quad (3)$$

donde  $B\rho(x)$  es el centro de una circunferencia con radio  $\rho > 0$ ,  $h > 0$  es el umbral del filtro y  $C(x) = \int_{B\rho(x)} \exp \frac{-|u(y)-u(x)|^2}{h^2} dy$  es el factor de normalización. El parámetro  $h$  controla el grado de similitud en la intensidad de los píxeles o el color, según con el tipo de imágenes con que se esté trabajando. El valor de este umbral depende de la desviación estándar  $\sigma$  del ruido, se sugiere que para un resultado aceptable del filtro su valor sea  $h = 2.5\sigma$ .

#### A. Non-Local Means

El filtro *Non-Local Means* es una variación más compleja del filtro *K-Nearest Neighbors* [3]. 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 se consideran 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  $x$ :

$$NL(v)(x) = \frac{1}{C(x)} \int_{\Omega} \exp \frac{-(Ga * |v(x+\cdot) - v(y+\cdot)|^2)_{(0)}}{h^2} v(y) dy \quad (4)$$

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

$$(Ga * |v(x+\cdot) - v(y+\cdot)|^2)_{(0)} = \int_{\mathbb{R}^2} Ga(t) |v(x+t) - v(y+t)|^2 dt \quad (5)$$

#### B. Fast Non-Local Means

Mientras que el filtro *K-Nearest Neighbors* se ejecuta en tiempo real (alrededor de 500 fps en una GPU de gama baja como la GTX 8800), el filtro *Non-Local Means* es mucho más lento. La razón principal de esto es la gran cantidad de recuperaciones de texturas: Para cada píxel es necesario calcular un número de  $N^2$  pesos. Para calcular cada peso es necesario que adicionalmente se calculen  $K^2$  pesos, donde  $(K = 2L + 1)$ , con  $L = \text{Radio del bloque}$ . Básicamente se realiza un número  $O(N^2 * K^2)$  de recuperaciones y solo reduciendo ese número de cálculos aumentará el rendimiento (en términos de tiempo). La solución sugerida es suponer que dentro de cada bloque los pesos no cambian. Por lo tanto, se calculan los pesos para el píxel central solamente y se usan estos pesos como coeficientes de convolución. De esta manera, el número de recuperaciones de textura se reduce a  $O(K^2)$ . Teniendo en cuenta que los valores más comunes para  $N = 7$  se hacen 49 veces menos recuperaciones de textura. La suposición de que los pesos son uniformes dentro de un bloque es bastante cierta. La mayoría de las áreas lisas se restauran sin diferencia visual con el filtro *Non-Local Means* original. Sin embargo, las áreas con bordes se pueden restaurar con artefactos. Los filtros *Fast Non-Local Means* y *K-Nearest Neighbors* se puede usar en combinación, con el objeto de que sus resultados sean más precisos que los resultados individuales, y aún más rápidos que la implementación original de *Non-Local Means*.

#### C. Implementación

La implementación y pruebas desarrolladas fueron realizadas con la siguiente arquitectura híbrida:

1. Laptop Alienware modelo R4 de 17 pulgadas con procesador Intel(R) Core(TM) i7-4720HQ CPU @ 2.60GHz con 4 núcleos, 16 GB de memoria RAM.
2. GPU GTX Titan X, con 24 multiprocesadores y 3072 núcleos, así como 12 GB de memoria RAM dedicada.
3. Amplificador de Gráficos Alienware, este dispositivo permite usar una tarjeta gráfica de gama alta como la GTX Titan X, en su interior tiene una única ranura PCI Express en la que se puede montar únicamente una GPU; además dispone de una fuente de alimentación de 460 Watts.

Bajo la filosofía del uso de software libre se utilizaron las siguientes herramientas computacionales:

1. Distribución de Linux Xubuntu 16.04.
2. Drivers de Nvidia para Ubuntu 16.04.
3. CUDA Toolkit 9.1.
4. GNU GCC version 5.4.0.
5. GPU-accelerated Libraries para computación heterogénea.

Como fuente de información se utilizaron las siguientes bases de datos:

1. BrainWeb: Simulated Brain Database [6, 7]. Permite simular imágenes de resonancia magnética tanto sanas como con lesiones, tanto en modalidades T1 y T2 con diferentes densidades de ruido 1%, 3%, 5%, 7% y 9%. Se simularon más de 10 estudios con alrededor de 140 imágenes cada uno.

2. International Multimodal Brain Tumor Segmentation (BraTS) Challenge 2017. Esta base de datos se usa para competencia a nivel internacional en el marco del congreso MICCAI (International Conference on Medical Image Computing and Computer Assisted Intervention) [4, 5]. La base de datos dispone de más de 240 estudios con más de 120 imágenes cada uno.

### III.RESULTADOS Y DISCUSIÓN

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) [8]. El segundo es cuantificar la preservación de los detalles finos de la imagen restaurada, está determinada por el error absoluto medio (MAE) [8]. El tercero, es el Índice de Similitud Estructural (SSIM) [9], 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 las siguientes expresiones:

$$PSNR = 10 \cdot \log \left[ \frac{(\max(x(i,j)))^2}{MSE} \right] \quad (6)$$

donde MSE es el Error Cuadrático Medio y es determinado mediante:

$$MSE = \frac{1}{M \cdot N} \sum_{i=1}^M \sum_{j=1}^N [(x(i,j) - \hat{e}(i,j))]^2 \quad (7)$$

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:

$$MAE = \frac{1}{M \cdot N} \sum_{i=1}^M \sum_{j=1}^N |x(i,j) - \hat{e}(i,j)| \quad (8)$$

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

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1) \cdot (2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1) \cdot (\sigma_x^2 + \sigma_y^2 + C_2)} \quad (9)$$

donde  $x$  es la imagen original,  $y$  es la imagen restaurada,  $\mu_x$  y  $\mu_y$  son los valores de la luminancia,  $\sigma_x$  y  $\sigma_y$  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.

#### A. Estudios de BrainWeb en modo T1

Utilizando el simulador BrainWeb se simulon 6 estudios con 181 imágenes cada uno de éstos. Los cuales fueron degradados con las siguientes densidades de ruido aditivo (Gaussiano): 0%, 1%, 3%, 5%, 7%, 9%. Para este primer experimento se trabajó con 1086 imágenes de resonancia magnética, en formato "PGM", con un rango dinámico de 8 bits, y un tamaño de 181x217 pixeles. En la TABLA 1 se presenta un resumen con los valores promedio de las 181 imágenes de cada estudio, para cada una de las métricas consideradas en esta evaluación.

TABLA 1. EVALUACIÓN PROMEDIO HECHO A ESTUDIOS DE BRAINWEB EN MODO T1.

Densidad de ruido	Algoritmo	PSNR (dB)	MAE	SSIM	Tiempo (s)
0 %	<i>K-Nearest Neighbors</i>	36.6634	1.5060	0.9172	0.0020
	<i>Non-Local Means</i>	34.9948	1.6820	0.9089	0.0062
	<i>Fast Non-Local Means</i>	33.5614	1.8642	0.9014	0.0019
1 %	<i>K-Nearest Neighbors</i>	36.6086	1.5256	0.9159	0.0021
	<i>Non-Local Means</i>	34.8959	1.7060	0.9069	0.0064
	<i>Fast Non-Local Means</i>	33.4644	1.8793	0.8998	0.0019
3 %	<i>K-Nearest Neighbors</i>	36.3011	1.5903	0.9079	0.0021
	<i>Non-Local Means</i>	34.5480	1.7889	0.8973	0.0065
	<i>Fast Non-Local Means</i>	33.2760	1.9400	0.8911	0.0020
5 %	<i>K-Nearest Neighbors</i>	35.4315	1.7407	0.8896	0.0022
	<i>Non-Local Means</i>	33.6788	1.9804	0.8738	0.0067
	<i>Fast Non-Local Means</i>	32.6602	2.1074	0.8680	0.0022
7 %	<i>K-Nearest Neighbors</i>	34.0481	1.9719	0.8727	0.0021
	<i>Non-Local Means</i>	32.0746	2.3139	0.8451	0.0067
	<i>Fast Non-Local Means</i>	31.3241	2.4226	0.8393	0.0023
9 %	<i>K-Nearest Neighbors</i>	32.7649	2.2109	0.8644	0.0021
	<i>Non-Local Means</i>	30.4145	2.7049	0.8195	0.0069
	<i>Fast Non-Local Means</i>	29.8793	2.7983	0.8139	0.0024

Una tendencia gráfica de estos resultados se muestra en la (c) (d)

Figura 1. Grosso modo se puede indicar que el algoritmo K-Nearest Neighbors presenta un mejor rendimiento en todos los criterios de evaluación. El algoritmo Non-Local Means tiene un rendimiento no tan distante del primer filtro; sin embargo, su costo computacional es más elevado, ya que como se mencionó con anterioridad considera la redundancia de información en toda la imagen.

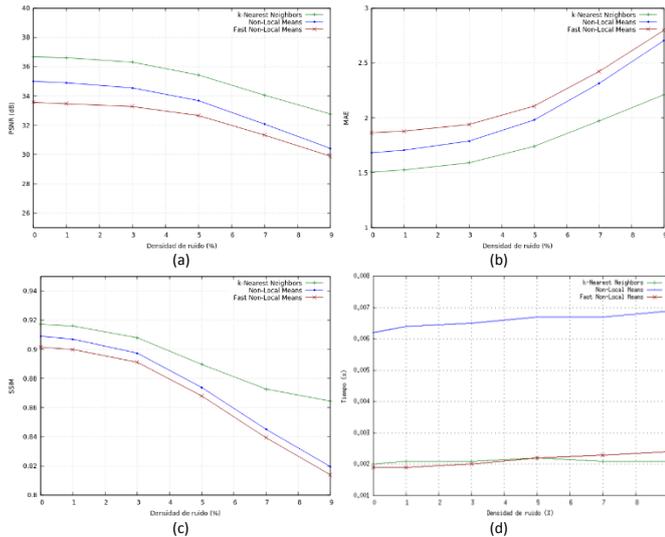


Figura 1. Evaluación gráfica hecha a estudios de BrainWeb en modo T1.

Por su parte la versión acelerada *Fast Non-Local Means* es equiparable al algoritmo *K-Nearest Neighbors* en cuanto al tiempo de ejecución, pero con el rendimiento más bajo, en gran medida al ser una versión con una disminución en el uso de la información global, se tiene a perder información significativa.

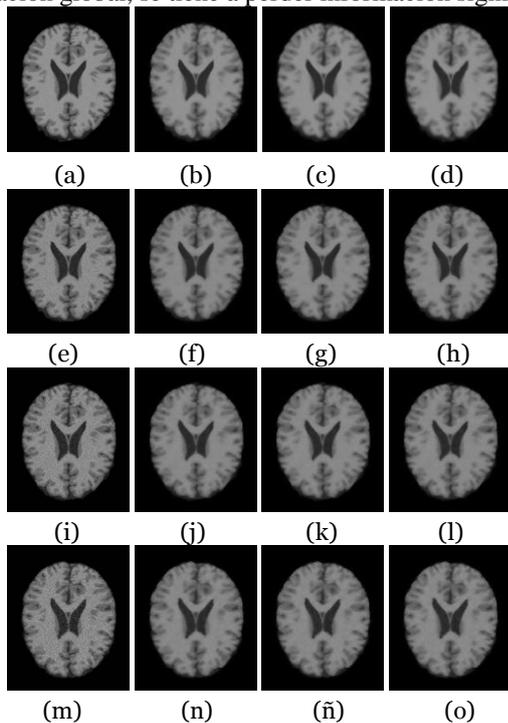


Figura 2. BrainWeb en modo T1: (a) 3 % ruido riciano, (b) KNN, (c) N-LM, (d) FN-LM, (e) 5 % ruido riciano, (f) K-NN, (g) N-LM, (h) FN-LM, (i) 7 % ruido riciano, (j) K-NN, (k) N-LM, (l) FN-LM, (m) 9 % ruido riciano, (n) K-NN, (o) N-LM, (p) FN-LM.

La evaluación cualitativa puede ser hecha a partir de la información sumariada en la Figura 2. Es posible observar que todos los algoritmos tuvieron la capacidad de reducir la presencia del ruido. Con una tendencia a suavizar las regiones

de las imágenes. Aspecto, que se puede considerar como una preservación de detalles mínima. Para resolver este problema, en la segunda parte de este proyecto se consideró el uso de técnicas de interpolación, que permitan resaltar los detalles finos de las imágenes restauradas del ruido.

### B. Estudios de BrainWeb en modo T2

De la misma forma que el experimento anterior, se utilizó el simulador BrainWeb para generar imágenes en modo T2 y se simularon 6 estudios con 181 imágenes cada uno. Para este experimento se consideró la simulación de imágenes de resonancia magnética con lesiones de esclerosis múltiple. Las cuales fueron degradadas con las siguientes densidades de ruido aditivo: 0%, 1%, 3%, 5%, 7%, 9%. Se simularon 1086 imágenes de resonancia magnética, en formato "PGM", con un rango dinámico de 8 bits, y un tamaño de 181x217 pixeles. La TABLA 2 proporciona un panorama general de la calidad de la supresión del ruido, así como el tiempo de ejecución de cada uno de los filtros evaluados.

TABLA 2. EVALUACIÓN PROMEDIO HECHO A ESTUDIOS DE BRAINWEB EN MODO T2.

Densidad de ruido	Algoritmo	PSNR (dB)	MAE	SSIM	Tiempo (s)
0 %	<i>K-Nearest Neighbors</i>	36.9561	1.5236	0.9157	0.0021
	<i>Non-Local Means</i>	34.4371	1.7663	0.9103	0.0061
	<i>Fast Non-Local Means</i>	31.1183	2.1874	0.9073	0.0021
1 %	<i>K-Nearest Neighbors</i>	36.6593	1.5492	0.9216	0.0021
	<i>Non-Local Means</i>	34.1620	1.8511	0.9144	0.0066
	<i>Fast Non-Local Means</i>	30.9090	2.0610	0.9026	0.0021
3 %	<i>K-Nearest Neighbors</i>	35.4954	1.7714	0.8970	0.0021
	<i>Non-Local Means</i>	33.0643	2.1377	0.8837	0.0069
	<i>Fast Non-Local Means</i>	30.7285	2.4191	0.8771	0.0022
5 %	<i>K-Nearest Neighbors</i>	33.6778	2.0631	0.8713	0.0021
	<i>Non-Local Means</i>	31.3180	2.5710	0.8423	0.0068
	<i>Fast Non-Local Means</i>	29.6673	2.8315	0.8359	0.0020
7 %	<i>K-Nearest Neighbors</i>	32.2939	2.3124	0.8634	0.0021
	<i>Non-Local Means</i>	29.7321	2.9721	0.8139	0.0070
	<i>Fast Non-Local Means</i>	28.4557	3.2214	0.8069	0.0021
9 %	<i>K-Nearest Neighbors</i>	31.3843	2.5045	0.8652	0.0019
	<i>Non-Local Means</i>	28.4579	3.3663	0.7961	0.0069
	<i>Fast Non-Local Means</i>	27.6085	3.5757	0.7906	0.0020

Al comparar con los resultados del experimento anterior, se puede observar una disminución de 2 unidades en la métrica PSNR. Una unidad en cuanto a la métrica MAE, las demás métricas no tuvieron una variación significativa. Se puede resumir que la variación de la intensidad de los pixeles en las imágenes de resonancia magnética impacta en el resultado cuantitativo obtenido por estas métricas. El comportamiento en

forma visual se puede observar en la Figura 3. Es notorio un mejor rendimiento del filtro *K-Nearest Neighbors*.

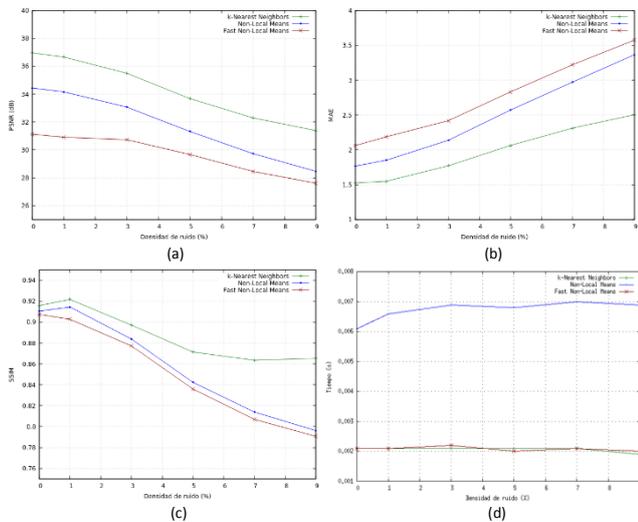


Figura 3. Evaluación gráfica hecha a estudios de BrainWeb en modo T2.

Una evaluación subjetiva puede ser hecha a partir de la Figura 4. Visualmente, se observa un mejor rendimiento de los algoritmos *Non-Local Means* y *Fast Non-Local Means*, si se hace una inspección visual en las Figura 4.k, 4.l, 4.ñ y 4.o, en contraste con las Figura 4.j y 4.n, ya que en estas últimas dos es notoria la presencia del ruido.

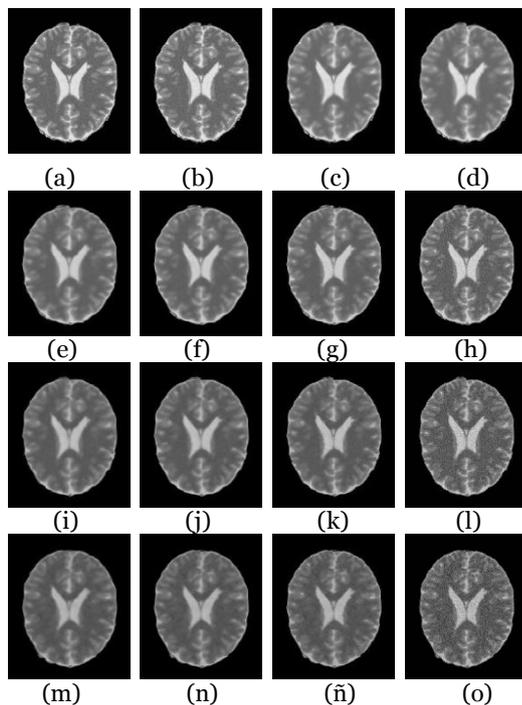


Figura 4. BrainWeb en modo T2: (a) 3 % ruido riciano, (b) KNN, (c) N-LM, (d) FN-LM, (e) 5 % ruido riciano, (f) K-NN, (g) N-LM, (h) FN-LM, (i) 7 % ruido riciano, (j) K-NN, (k) N-LM, (l) FN-LM, (m) 9 % ruido riciano, (n) N-LM, (o) FN-LM

C. Estudios de BraTS 2017

Para este experimento se probó la capacidad real de los algoritmos evaluados, al usarse una base de datos real, en dónde se desconoce el nivel de ruido. La base de datos contiene 250 estudios, los cuales tienen información de imágenes de resonancia magnética adquiridas bajo la modalidad T1, T2 y T1ce. (116, 250 imágenes). Es conveniente resaltar, que la última modalidad es utilizada para identificar las anomalías (tumores) presentes en los estudios. El tamaño de cada imagen es de 240x240 pixeles, en formato JPG y con un rango dinámico de 8 bits.

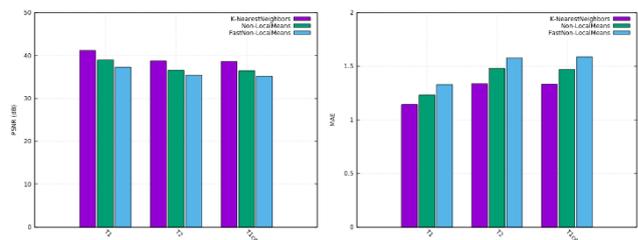
A fin de trabajar con estas imágenes fue necesario convertirlas a formato PGM, ya que CUDA en su forma convencional solo acepta imágenes en formato PGM (escala de grises) y PPM (a color).

La evaluación objetiva es resumida en la TABLA 3. Se presenta un incremento en la métrica PSNR, dado por el resultado promedio de todas las imágenes consideradas en este experimento. Así como un decremento en las métricas MAE y SSIM. En cuanto al tiempo de ejecución este se incrementó, dado el número de imágenes evaluadas.

TABLA 3. EVALUACIÓN PROMEDIO HECHA A ESTUDIOS DE BRATS 2017.

Modo	Algoritmo	PSNR (dB)	MAE	SSIM	Tiempo (s)
T 1	<i>K-Nearest Neighbors</i>	41.1353	1.1429	0.9005	0.400
	<i>Non-Local Means</i>	38.9310	1.2304	0.8968	1.775
	<i>Fast Non-Local Means</i>	37.2828	1.3274	0.8915	0.450
T 2	<i>K-Nearest Neighbors</i>	38.7112	1.3344	0.8943	0.450
	<i>Non-Local Means</i>	36.5579	1.4788	0.8862	1.853
	<i>Fast Non-Local Means</i>	35.3327	1.5751	0.8787	0.500
T 1ce	<i>K-Nearest Neighbors</i>	38.5892	1.3325	0.8916	0.405
	<i>Non-Local Means</i>	36.4636	1.4701	0.8836	1.675
	<i>Fast Non-Local Means</i>	35.1718	1.5876	0.8763	0.452

Estos resultados pueden ser corroborados de manera gráfica en la Figura 5, resultando demasiado notorio como el algoritmo *Non-Local Means* requiere más tiempo para suprimir el ruido del lote de imágenes.



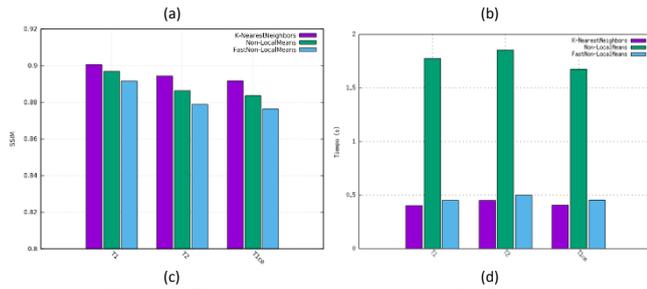


Figura 5. Evaluación gráfica de la base BraTS 2017.

Para ejemplificar directamente sobre las imágenes, se tomó al azar una imagen en sus tres modalidades T1, T2 y T1ce, estas y los resultados de la supresión de ruido son presentados en la Figura 6.

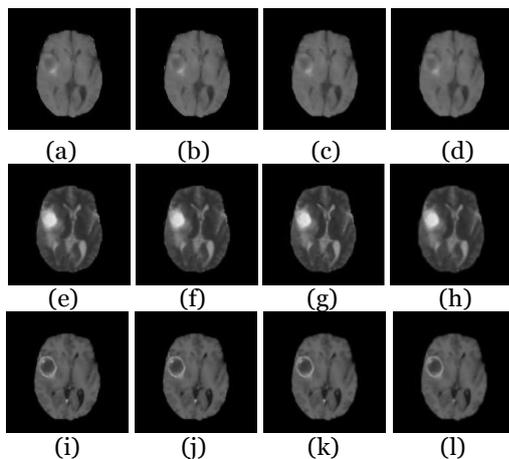


Figura 6. BraTS 2017: (a) T1 ruido riciano, (b) K-NN, (c) NLM, (d) FN-LM, (e) T2 ruido riciano, (f) K-NN, (g) N-LM, (h) FN-LM, (i) T1ce ruido riciano, (j) K-NN, (k) N-LM, (l) FN-LM

La complejidad de esta base de datos queda expuesta en estas imágenes, ya que las cuatro regiones normales que existen (materia gris, blanca y fluido cerebroespinal, fondo), así como la anomalías presentes tienen el problema de la variación de información; es decir, los contornos de estas regiones están pobremente definidas, lo cual influye en que no se puedan delimitar. Aun así los filtros evaluados no destruyeron por completo estas fronteras.

#### IV. CONCLUSIONES

Se evaluaron tres algoritmos existentes en la literatura, diseñados para la supresión de ruido riciano en imágenes de resonancia magnética. La aportación más importante está dada por su implementación en un sistema heterogéneo conformado por una CPU más una GPU. Como el objetivo general planteado en este proyecto fue un sistema para procesamiento de imágenes en tiempo real, se consideró un sistema de alto rendimiento basado en el denominado súper cómputo, es decir computación paralela.

Los resultados obtenidos permitieron verificar la capacidad de supresión del ruido riciano de los métodos evaluados, el tiempo total de ejecución de los filtros sugiere que su modo de operación puede considerarse en tiempo real. El rendimiento más destacado fue el del filtro K-Nearest Neighbors. Aunque se considera que la redundancia de información es de mucha ayuda, para este tipo de imágenes la información local resultó más significativa, este tipo de filtros como su nombre lo sugiere utiliza la información de los vecinos más cercanos para hacer los cálculos correspondientes.

Aunque en la literatura el filtro *Non-Local Means* es muy popular por su rendimiento, con la experimentación quedó comprobado que su rendimiento no es el mejor, aunado a que su tiempo de ejecución es alto. Por su parte el filtro *Fast Non-Local Means* es una versión acelerada del filtro *Non-Local Means*, su rendimiento fue el más bajo, aunque su tiempo de ejecución es equiparable con el del filtro *K-Nearest Neighbors*.

#### REFERENCIAS

- [1] Gunturk, B. K., & Li, X. (Eds.). (2012). Image restoration: fundamentals and advances. CRC Press.
- [2] Scherzer, O. (Ed.). (2010). Handbook of mathematical methods in imaging. Springer Science & Business Media.
- [3] Kharlamov, A., & Podlozhnyuk, V. (2007). Image denoising. NVIDIA.
- [4] Menze, B. H., Jakab, A., Bauer, S., Kalpathy-Cramer, J., Farahani, K., Kirby, J., ... & Lanczi, L. (2015). The multimodal brain tumor image segmentation benchmark (BRATS). IEEE transactions on medical imaging, 34(10), 1993-2024.
- [5] <http://www.miccai2018.org/en/>
- [6] Cocosco, C. A., Kollokian, V., Kwan, R. K. S., Pike, G. B., & Evans, A. C. (1997). Brainweb: Online interface to a 3D MRI simulated brain database. In NeuroImage.
- [7] <http://brainweb.bic.mni.mcgill.ca/brainweb/>
- [8] Mújica-Vargas, D., de Jesús Rubio, J., Kinani, J. M. V., & Gallegos-Funes, F. J. (2018). An efficient nonlinear approach for removing fixed-value impulse noise from grayscale images. Journal of Real-Time Image Processing, 14(3), 617-633.
- [9] Wang, Z., Simoncelli, E. P., & Bovik, A. C. (2003, November). 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.
- [10] J. Rajan, J. Arnold, J. Sijbers, A new non-local maximum likelihood estimation method for rician noise reduction in magnetic resonance images using the kolmogorov-smirnov test, Signal processing 103 (2014) 16-23.
- [11] H. Li, C. Y. Suen, A novel non-local means image denoising method based on grey theory, Pattern Recognition 49 (2016) 237-248.
- [12] B. Liu, X. Sang, S. Xing, B. Wang, 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) (2015) 2955-2959.
- [13] H. V. Bhujle, S. Chaudhuri, Laplacian based non-local means denoising of mr images with rician noise, Magnetic resonance imaging 31 (9) (2013) 1599-1610.
- [14] A. Martin, J. F. Garamendi, E. Schiavi, Mr-dti rician denoising, Dyna 80 (182) (2013) 25-30.
- [15] G. Chen, P. Zhang, Y. Wu, D. Shen, P.-T. Yap, Denoising magnetic resonance images using collaborative non-local means, Neurocomputing 177 (2016) 215-227.
- [16] D. Ai, J. Yang, J. Fan, W. Cong, X. Wang, Denoising filters evaluation for magnetic resonance images, Optik-international journal for light and electron optics 126 (23) (2015) 3844-3850.

- [17] L. Tan, L. Shi, Multiwavelet-based estimation for improving magnetic resonance images, in: *Image and Signal Processing, 2009. CISP'09. 2nd International Congress on, IEEE, 2009*, pp. 1–5.
- [18] F. Zhang, L. Ma, Mri denoising using the anisotropic coupled diffusion equations, in: *Biomedical Engineering and Informatics (BMEI), 2010 3rd International Conference on, Vol. 1, IEEE, 2010*, pp. 397–401.
- [19] M. Sharif, M. A. Jaffar, M. T. Mahmood, Optimal composite morphological supervised filter for image denoising using genetic programming: application to magnetic resonance images, *Engineering Applications of Artificial Intelligence* 31 (2014) 78–89.
- [20] R. W. Liu, L. Shi, W. Huang, J. Xu, S. C. H. Yu, D. Wang, Generalized total variation-based mri rician denoising model with spatially adaptive regularization parameters, *Magnetic resonance imaging* 32 (6) (2014) 702–720.
- [21] S. A. Akar, Determination of optimal parameters for bilateral filter in brain mr image denoising, *Applied soft computing* 43 (2016) 87–96.
- [22] X. Wang, S. Shen, G. Shi, Y. Xu, P. Zhang, Iterative non-local means filter for salt and pepper noise removal, *Journal of visual communication and image representation* 38 (2016) 440–450.
- [23] T.-A. Nguyen, A. Nakib, H.-N. Nguyen, Medical image denoising via optimal implementation of non-local means on hybrid parallel architecture, *Computer methods and programs in biomedicine* 129 (2016) 29–39.
- [24] J. Mohan, V. Krishnaveni, Y. Guo, A survey on the magnetic resonance image denoising methods, *Biomedical Signal Processing and Control* 9 (2014) 56–69.
- [25] A. Buades, B. Coll, J.-M. Morel, A review of image denoising algorithms, with a new one, *Multiscale Modeling & Simulation* 4 (2) (2005) 490–530.
- [26] A. Khan, M. Waqas, M. R. Ali, A. Altalhi, S. Alshomrani, S.-O. Shim, Image de-noising using noise ratio estimation, k-means clustering and non-local means-based estimator, *Computers & Electrical Engineering* 54 (2016) 370–381.
- [27] M. Lysaker, A. Lundervold, X.-C. Tai, Noise removal using fourth-order partial differential equation with applications to medical magnetic resonance images in space and time, *IEEE Transactions on image processing* 12 (12) (2003) 1579–1590.
- [28] J. Yang, J. Fan, D. Ai, X. Wang, Y. Zheng, S. Tang, Y. Wang, Local statistics and non-local mean filter for speckle noise reduction in medical ultrasound image, *Neurocomputing* 195 (2016) 88–95.