

# Fusión de imágenes médicas multimodales a partir de la maximización de su información mutua

**Ariel Hernández, Claudio Verrastro**

Comisión Nacional de Energía Atómica, Pbro. Juan González y Aragón nº 15 (B1802AYA) Ezeiza, Provincia de Buenos Aires, Argentina

*ahernandez@cae.cnea.gov.ar*

*Recibido el 20 de diciembre de 2015, aprobado el 4 de febrero de 2016*

---

## Resumen

La utilización de imágenes médicas es una herramienta vital dentro del área de diagnóstico, planificación, ejecución y evaluación de los procedimientos quirúrgicos y radioterapéuticos. Por esta razón es muy útil la integración de la información proveniente de diferentes imágenes médicas mediante alineación de ellas en base a su correlación o información en común, con el objetivo de obtener la mejor coincidencia espacial. El algoritmo implementado en este trabajo se realizó en el contexto del proyecto AR-PET de la Comisión Nacional de Energía Atómica (CNEA) y utiliza la información mutua y la técnica Metrópolis como medida de similitud y método de búsqueda estocástica respectivamente. La fusión de imágenes 2D se realizó a partir de la maximización de su información mutua y con transformaciones de rotación y traslación, con resultados satisfactorios en cuanto a la alineación geométrica de las mismas.

**PALABRAS CLAVE:** IMÁGENES MÉDICAS – REGISTRACIÓN – INFORMACIÓN MUTUA – METRÓPOLIS NES DE IRRADIACIÓN

## Abstract

Medical Imaging is a vital tool within the areas of diagnostic, planning, implementation and evaluation of surgical and radiotherapy procedures. For this reason, it is helpful to integrate the information from different medical images by aligning them according to their correlation or information in common, with the aim of getting the best spatial coincidence. The algorithm presented in this work has been developed within the context of the AR-PET project belonging to the National Atomic Energy Commission (CNEA in Spanish). The key in the process of developing the algorithm is mutual information and the Metropolis technique as a similarity measure and search method respectively. The 2D fusion imaging has been achieved by maximizing mutual information and carrying out rigid transformations of rotation and translation with satisfactory results with respect to their geometric alignment.

**KEYWORDS:** MEDICAL IMAGING – REGISTRATION – MUTUAL INFORMATION – METROPOLIS

## Introducción

Dentro del actual contexto clínico, la utilización de imágenes médicas es una herramienta importante para el diagnóstico y tratamiento de distintas patologías. Se utilizan en un gran número de estudios que se prescriben durante todo el seguimiento del paciente, no solo durante el diagnóstico, sino también en las de planificación, ejecución y evaluación de los procedimientos quirúrgicos y radioterapéuticos (Maintz, 1998). Durante la etapa de diagnóstico algunos estudios médicos dan como resultado imágenes que se distinguen por mostrar diferentes aspectos de la misma patología. Bajo este concepto, es muy útil la integración de la información proveniente de los diferentes equipos. Cuando se alinean geométricamente las imágenes combinando la información otorgada por cada una, se logra una mejor observación y un diagnóstico mucho más acertado. Este procedimiento de mapear puntos de una imagen a sus correspondientes en otra, se denomina *fusión o registración de imágenes* (Wyawahre, 2009). La técnica de registración es fundamental en el seguimiento de tratamientos, evolución de lesiones y progresión de enfermedades, permitiendo al profesional obtener un panorama más claro al momento de definir un diagnóstico.

La fusión de imágenes es el proceso de alineación de dos imágenes en base a su correlación o información en común, y tiene como objetivo determinar una transformación tal que ambas tengan la mejor coincidencia espacial (Chumchob, 2009). Las imágenes entre sí suelen tener una o más de las siguientes características (Wyawahre, 2009):

- Fueron adquiridas en distinto tiempo.
- Proviene de distintos dispositivos de diagnóstico como Resonancia Magnética (MRI), Tomografía Computada (CT), Tomografía de Emisión de Positrones (PET), Tomografía Computada por Emisión de Fotón Único (SPECT), etc.
- Se adquirieron desde diferentes ángulos para obtener una perspectiva 2D o 3D.

Las imágenes pueden provenir del mismo equipo de diagnóstico, método *monomodal*, o proveniente de diferentes equipos, en este caso se denomina método *multimodal* (Maintz, 1998). En este último caso, normalmente, se comparan imágenes anatómicas (MRI o CT)

e imágenes metabólicas (PET o SPECT). La transformación espacial se aplica siempre a las imágenes metabólicas (denominada *objetivo o detectada*) utilizando como referencia las imágenes anatómicas (denominada *referencia o fuente*). Actualmente hay equipos combinados como PET-CT o PET-MRI que facilitan la registración porque el paciente se encuentra en la misma posición.

En un algoritmo de registración de imágenes se presentan cuatro etapas básicas (Kostelec, 2003):

1. *Espacio de características*, este espacio se refiere a las características elegidas en la imagen para realizar el proceso de alineación, como por ejemplo el *valor del pixel* o la información del *contorno o picos* de objetos identificados dentro de ella. En función de esta elección, se determinan qué técnicas serán utilizadas en la registración.

2. *Espacio de búsqueda*, en esta etapa se define el tipo de transformación para la alineación de las imágenes. Las tres clases de transformaciones básicas son: rígidas (traslación y rotación), afín (traslación, cambio de escala, rotación y sesgado o transvección) y no rígidas (transformaciones elásticas).

3. *Estrategia de búsqueda*, mecanismo para la elección de las sucesivas transformaciones de la imagen objetivo para obtener una registración óptima. Una de las más comunes es *hill climbing*, es una estrategia irrevocable y puede estancarse en máximos locales.

4. *Medida de similitud*, en esta etapa se elige el mecanismo de cuantificación de las diferencias geométricas entre ambas imágenes, este cálculo se realiza después de cada transformación aplicada en cada una de las iteraciones del algoritmo, es la medida de comparación que indica la similitud. Existen diferentes estrategias utilizadas como medida de similitud: correlación, error cuadrático medio e información mutua.

Este trabajo se realizó dentro proyecto ARPET de la Comisión Nacional de Energía Atómica (CNEA) (SECYT, 2011; FCDN, 2014). El objetivo es obtener un método de registración para imágenes 2D que utiliza como Medida de Similitud la maximización de la información

mutua (Viola, 1997) y el algoritmo Metr polis (tambi n llamado de *Recocido Simulado*) como m todo de b squeda estoc stica (Beich, 2000). Con este proceso se busca alinear las im genes obtenidas por el equipo AR-PET con im genes de tomograf a computada o resonancia magn tica. Estas im genes as  alineadas permiten calcular coeficientes de atenuaci n a partir de las im genes CT o RMI para la correcci n de las im genes PET y para ampliar la capacidad diagn stica del equipo.

La implementaci n del algoritmo fue realizado en MATLAB y se utilizaron im genes provenientes del *Insight Journal Database* (Insight). Los resultados obtenidos fueron satisfactorios mostrando un importante grado de robustez al momento de realizar el proceso de registraci n como se ver  en las secciones de Resultados y Conclusiones.

### Metodolog a

En los  ltimos tiempos los conceptos de *teor a de la informaci n* se tornan cada vez m s relevantes, dando sus primeros pasos en el  rea de las telecomunicaciones y luego migrando hacia otros campos de la ingenier a. De este contexto surge la necesidad de encontrar una medida que cuantifique la *informaci n*. En 1928 Harley define la primera medida de la cantidad de informaci n de una secuencia de datos, y en 1948 Shannon el concepto y la formulaci n matem tica de *entrop a* (Caro, 2004), que adapta la medida introducida por Harley para s mbolos de diferente probabilidad de ocurrencia. La entrop a depende directamente del concepto de autoinformaci n o *self-information*, donde la cantidad de autoinformaci n contenida en un evento probabilistico depende unicamente de la probabilidad de tal evento, entonces cuanto menor es la probabilidad, mayor ser  la autoinformaci n asociada con la recepci n de la informaci n de dicho evento. Por lo tanto, se define la autoinformaci n  $I$  asociada al evento  $n$  de una variable aleatoria  $A$  con una probabilidad asociada  $p_A$  como:

$$I(A_n) = \log\left(\frac{1}{p_A(n)}\right) = -\log(p_A(n)) \quad (1)$$

Cuando el logaritmo se encuentra en base 2, la unidad de la autoinformaci n es *bits*. De esta

manera, la entrop a de una variable aleatoria  $A$  se define como la esperanza de la autoinformaci n  $I$ , es decir:

$$H(A) = E(I(A)) = E(-\log(p_A)) \quad (2)$$

De esta manera la entrop a  $H$  para una variable aleatoria  $A$ , conformada por una secuencia de s mbolos diferentes, cada uno con su respectiva probabilidad de ocurrencia  $p_A(i)$  puede definirse como:

$$H(A) = \sum p_A(i)I(A_i) = -\sum p_A(i) \cdot \log(p_A(i)) \quad (3)$$

$H(A)$  puede verse como una *medida de incertidumbre*, ya que su valor m ximo est  determinado cuando todos los s mbolos tienen igual probabilidad de ocurrencia. En el caso que un s mbolo tenga una mayor probabilidad que el resto genera una reducci n en la incertidumbre (ya que este s mbolo va a ocurrir la mayor parte de las veces) y por ende una reducci n en la entrop a. Las im genes pueden tambi n ser consideradas como portadoras de informaci n, aunque en lugar de probabilidades de ocurrencia de letras en un mensaje, se estudia la distribuci n de valores de sus p xeles. En este caso, en la ecuaci n (3) la variable  $A$  es una imagen. A modo de ejemplo, es sencillo inferir que una imagen uniforme en tonos de gris no posee informaci n (Caro, 2004).

Dada la definici n de entrop a, es intuitivo pensar que usar conceptos que involucren y relacionen entre s  las entrop as de dos variables aleatorias puede servir en el registro de im genes. En efecto, Woods (Caro, 2004) propuso usar las entrop as conjuntas para una medida de registro de las im genes, definida como:


$$H(A, B) = -\sum p_{A,B}(i, j) \cdot \log(p_{A,B}(i, j)) \quad (4)$$

Donde  $A, B$  son las im genes a registrar y  $p_{A,B}(i, j)$  su funci n de probabilidad conjunta de ocurrencia de cada uno de sus p xeles.

Woods sostuvo que tonos de grises similares en ambas im genes correspond an a tejidos similares en dos im genes m dicas correspondientes a distintas modalidades. Luego Hill et al. definieron lo que llamaron un Espacio de Ca-

racterísticas (*feature space*). De esta manera plantearon que similares tejidos se mapeaban en la misma región del Espacio de Características. Este espacio hace referencia al *histograma conjunto*, y cambia con la alineación de las imágenes, que permite calcular la distribución de probabilidad conjunta entre las imágenes (Caro, 2004).

A partir de esto, Viola y Wells (Viola, 1997) optaron por utilizar *la información mutua o MI* entre imágenes como métrica para el proceso de registración, utilizando el concepto de *entropía*.



**Fig.1. Diagrama de Venn correspondiente a la información mutua** (Sander, 2015)

La información mutua de dos variables aleatorias es una cantidad que mide la dependencia mutua entre ellas, es decir, mide la reducción de la incertidumbre (*entropía*) de una variable aleatoria,  $X$ , debido al conocimiento del valor de otra variable aleatoria  $Y$  (Figura 1). La información mutua es una medida de la información común a dos variables aleatorias. Formalmente la información mutua de dos imágenes  $A$  y  $B$  puede ser definida como:

$$MI(A, B) = \sum \sum p_{A,B}(i, j) \log \left( \frac{p_{A,B}(i, j)}{p_A(i)p_B(j)} \right) \quad (5)$$

Donde  $p_A(i)$  y  $p_B(j)$  son las funciones de probabilidad de las variables  $A$  y  $B$  respectivamente. Se puede destacar que si las variables  $A$  y  $B$  son independientes, nos queda que  $p_{A,B}(i, j) = p_A(i)p_B(j)$  y el valor de MI es nulo, es decir:

$$\frac{p_{A,B}(i, j)}{p_A(i)p_B(j)} = 1 \Rightarrow \log \left( \frac{p_{A,B}(i, j)}{p_A(i)p_B(j)} \right) = 0 \Rightarrow MI = 0 \quad (6)$$

Si reemplazamos las ecuaciones (3) y (4) en la ecuación (5) la información mutua puede adoptar tres formas distintas:

$$1. MI(A, B) = H(B) - H(B/A) = H(A) - H(A/B) \quad (7)$$

En esta definición la información mutua entre  $A$  y  $B$  está dada por la entropía de una de ellas menos su entropía a partir del conocimiento de la otra imagen.

$$2. MI(A, B) = H(B) + H(A) - H(A, B) \quad (8)$$

Esta definición puede interpretarse como la suma de sus incertidumbres menos la entropía conjunta, dando como resultado la información compartida o mutua.

$$3. MI(A, B) = H(A, B) - H(A/B) - H(B/A) \quad (9)$$

Finalmente, la información mutua puede obtenerse a partir de la entropía conjunta menos las incertidumbres de cada una de las imágenes a partir del conocimiento de la otra.

En la Figura 1 se puede observar el diagrama de Venn que ilustra la información mutua como el área de intersección entre los dos conjuntos que corresponden a cada una de las imágenes.

Viola y Wells (Ibíd.) proponen un método de alineación de imágenes basado en la maximización de la información mutua entre ellas. Una de las ventajas más importantes es que se basa en valores de intensidad, el cual muestra una mayor robustez que el uso de la *correlación*. Bajo este concepto, en este trabajo se plantea un algoritmo iterativo de registración a partir de la maximización de la información mutua entre dos imágenes. Para lograr este objetivo se utiliza el algoritmo Metrópolis (Beich, 2000) que permite encontrar un valor máximo local de la información mutua.

Con respecto a la alineación se utiliza una matriz de transformación rígida, es decir que solo contempla rotación y traslación de la imagen *objetivo* con respecto a la de *referencia*. La matriz de transformación está dada por la siguiente expresión:

$$M = \begin{pmatrix} \cos(\Theta) & \sin(\Theta) & 0 \\ -\sin(\Theta) & \cos(\Theta) & 0 \\ t_x & t_y & 1 \end{pmatrix} \quad (10)$$

Donde los parámetros  $\Theta$ ,  $t_x$  y  $t_y$  corresponden al ángulo de rotación, al desplazamiento en la dirección de X y al desplazamiento en la dirección de Y respectivamente. Por lo tanto, el principal objetivo es encontrar el valor de estos parámetros tal que la información mutua entre las imágenes sea máxima, es decir, se encuentren alineadas (Viola, 1997).

Existen diferentes métodos de maximización de la información mutua, en el caso del algoritmo Metrópolis, se realiza un sorteo probabilístico para estimar el valor de los parámetros de rototraslación a partir del valor de la información mutua en forma iterativa.

El algoritmo Metrópolis genera una secuencia de variables aleatorias a partir de una distribución probabilística (generalmente gaussiana) cuando no es posible el muestreo directo. En este caso, estas variables corresponden a los parámetros  $\Theta$ ,  $t_x$  y  $t_y$ , donde la función de probabilidad conjunta  $p_{A,B}$  es función de ellos, ya que cualquier transformación geométrica entre las imágenes a registrar modifica directamente su  $p_{A,B}$ . Al variar la función  $p_{A,B}$ , como se observa en las ecuaciones (4), (5), (7), (8) y (9), la información mutua se ve afectada también. De esta manera, en cada iteración del algoritmo se calcula la  $MI$  para cada sorteo de los parámetros y se verifica si la  $MI$  actual es mayor al valor que se tiene como referencia, en el caso de resultar mayor, este es el nuevo  $MI$  de referencia y se guardan los parámetros asociados y se los clasifica como *aceptados*, caso contra-


rio se evalúa una probabilidad de ser *aceptado* como se verá más adelante. Esto se lo conoce como *condición de aceptación*.

Entonces, en primer lugar se calcula la información mutua entre las imágenes *objetivo* y *referencia*, se inicializan los parámetros y se genera una distribución gaussiana para cada uno de ellos centrada en sus respectivos valores iniciales. Estos valores son los primeros valores que cumplen la *condición de aceptación* del algoritmo, es decir, son los primeros parámetros aceptados. Por lo tanto:


$$\begin{aligned} \Theta_{aceptado} &= \Theta_0 \\ t_{x_{aceptado}} &= t_{x_0} \\ t_{y_{aceptado}} &= t_{y_0} \\ mi_{aceptado} &= MI(referencia, objetivo) \end{aligned} \quad (11)$$

$$\begin{aligned} \Theta &\sim N(\mu_{\Theta_{aceptado}}, \sigma_{\Theta_{aceptado}}) \\ t_x &\sim N(\mu_{t_{x_{aceptado}}}, \sigma_{t_{x_{aceptado}}}) \\ t_y &\sim N(\mu_{t_{y_{aceptado}}}, \sigma_{t_{y_{aceptado}}}) \end{aligned} \quad (12)$$

Los desvíos de cada una de las distribuciones de probabilidad se calculan a partir de una expresión cuadrática que varía con el número de iteración  $i$ , es decir, que en la medida que aumenta el valor de  $i$ , disminuye el desvío estándar (sigma) de la distribución. En la Figura 2 se puede observar cómo varía el valor de sigma durante todo el proceso, que como condición de diseño, alcanza un valor máximo de 2500 iteraciones (configurable hasta 5000 iteraciones).



### a) Variación del desvío estándar en función de las iteraciones



### b) Distribución de probabilidad de los parámetros

**Fig.2. Configuración del valor de desvío estándar para los parámetros de la matriz M**  
(Fuente: Elaboración propia)

Si definimos la ecuación cuadrática simétrica de la siguiente manera:

$$\sigma(x) = ax^2 + b \quad (13)$$

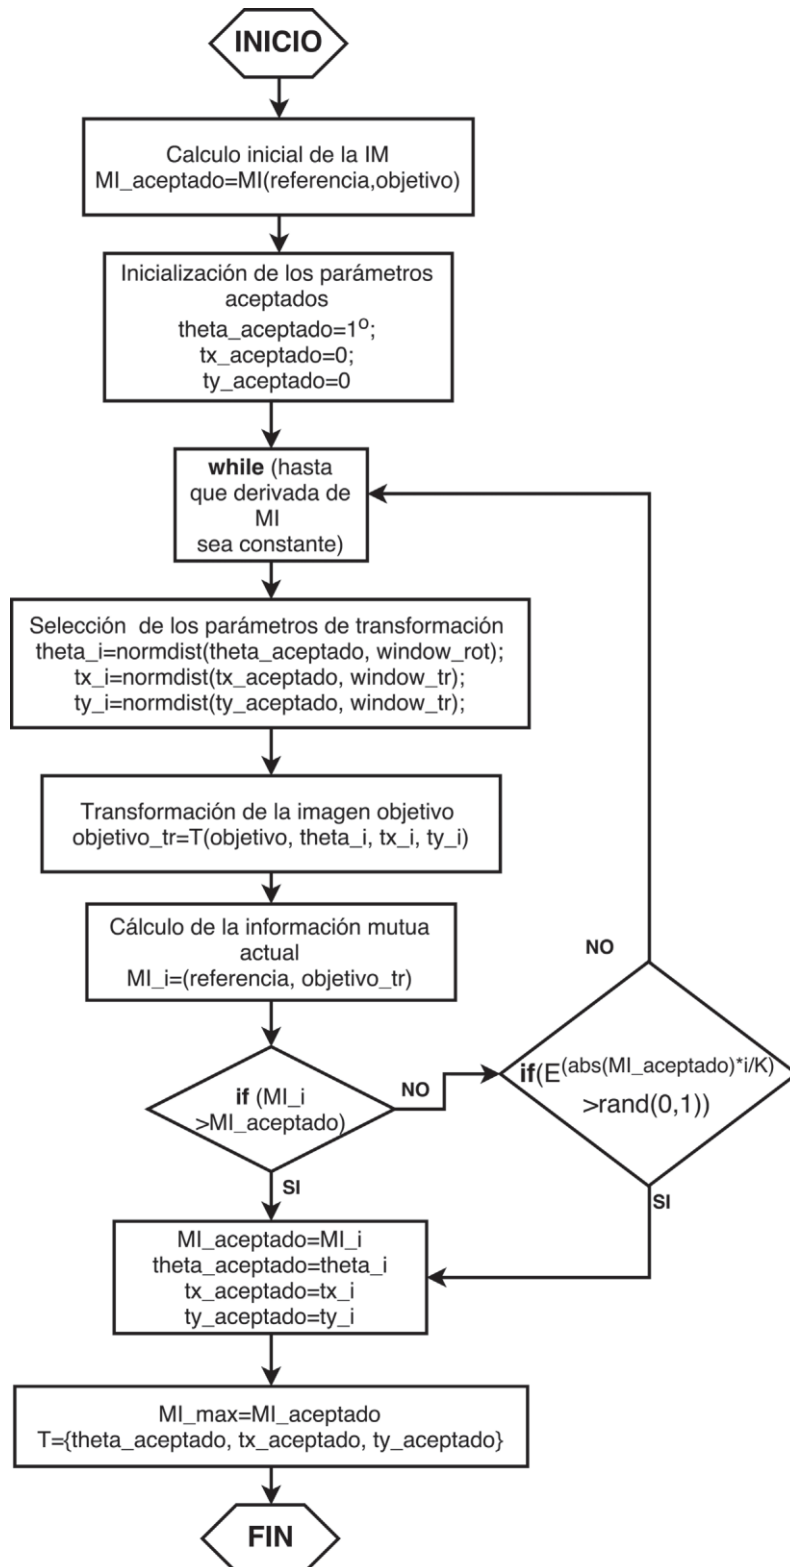
En la Tabla 1 se muestran los coeficientes de la curva cuadrática (ecuación (13)) para cada uno de los parámetros. Cabe destacar que las curvas están calculadas para un máximo de 5000 iteraciones, pero por defecto está configurado en un valor de 2500 iteraciones.

A continuación se estiman los nuevos valores de los tres parámetros en la iteración  $i$  a partir de las distribuciones gaussianas definidas en el inicio con media en el parámetro aceptado y un desvío estándar que varía inversamente proporcional al número de iteraciones. Con estos parámetros se le aplica la trans-

formación geométrica a la imagen *objetivo* y se calcula su información mutua  $mi_i$ . En esta instancia se aplica el criterio de aceptación mencionado anteriormente entre el valor de  $mi_i$  con el de  $mi_{aceptado}$ . Si en el resultado de esta comparación surge que el valor de  $mi_i$  es mayor, es el nuevo valor de información mutua aceptado. A su vez, se registran también los valores de  $\Theta_i$ ,  $t_{xi}$  y  $t_{yi}$  como  $\Theta_{aceptado}$ ,  $t_{x_{aceptado}}$ ,  $t_{y_{aceptado}}$  respectivamente, y se reconfiguran las distribuciones gaussianas con los nuevos valores. En el caso de que el valor de  $mi_i$  fuera menor se aplica la técnica de recido simulado (o *simulated annealing*), donde se le asigna una probabilidad aleatoria de ser aceptado a través de la ecuación (14). Esta técnica evita caer en máximos locales de la función. En la Figura 3 se muestra el diagrama de flujo del algoritmo.

Parámetro	a	b	Valor mínimo de $\sigma$ en $i = 5000$	Valor máximo de $\sigma$ en $i = 0$
$\Theta$	$-\pi/2 E^{-10}$	$\pi/4$	$\pi/8$	$\pi/4$
$t_x$	$-4 E^{-8}$	2	1	2
$t_y$	$-4 E^{-8}$	2	1	2

**Tabla 1. Coeficientes de las curvas cuadráticas para el cálculo del desvío estándar en cada parámetro de M** (Fuente: Elaboración propia)



**Fig.3. Diagrama de flujo del algoritmo de registración**  
(Fuente: Elaboración propia)

$$E(-abs(mi_{aceptado}-mi_i)*\frac{i}{K}) > rand(0,1) \quad (14)$$

La ecuación (14) solo se aplica para pequeñas diferencias entre  $mi_i$  y el  $mi_{aceptado}$  e indica que  $mi_i$  es aceptado si el valor del miembro de la izquierda es mayor a un número aleatorio entre cero y uno, correspondiente a una variable aleatoria distribuida de manera uniforme. La constante K en la ecuación (14) se obtuvo de manera empírica y su valor es 20.

Este proceso finaliza cuando se da una de las siguientes condiciones:

1. Cuando la variación de la derivada de la información mutua es cero durante un determinado número de iteraciones.
2. Cuando el algoritmo llega a un número máximo de iteraciones.

En la primera condición se analiza el valor de la información mutua a lo largo del proceso y se observa el tiempo en el cual este valor se mantiene constante, es decir:

$$\Delta mi_{aceptado} = mi(i) - mi_{aceptado}(i - 1) = 0 \quad (15)$$

La condición correspondiente a la ecuación (11) indica que el valor de la información mu-

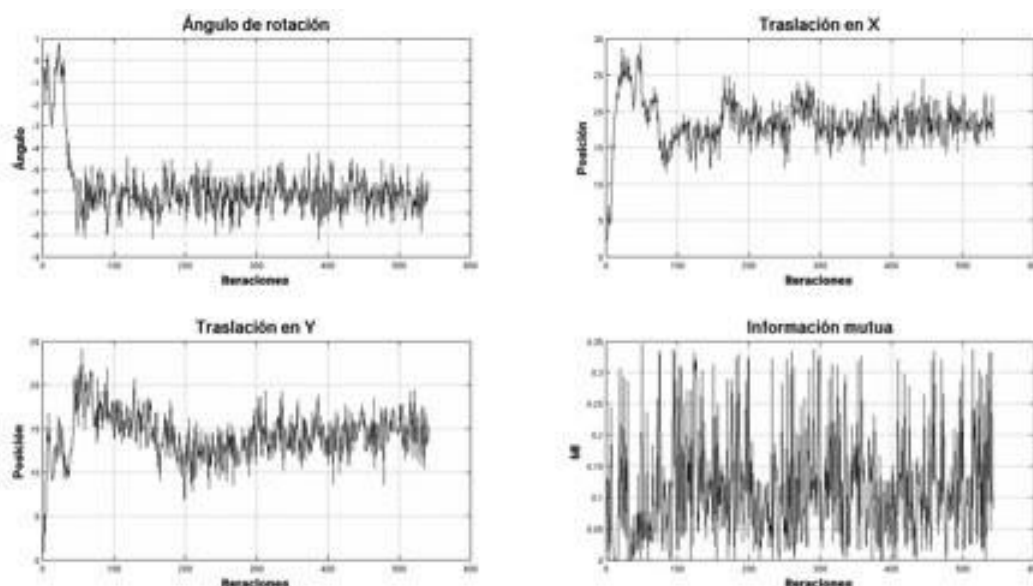
tua entre las iteraciones  $i$  e  $(i-1)$  es constante, y una vez que esta condición se haya cumplido durante un número específico de iteraciones el algoritmo finaliza el proceso. Esto indica que durante un determinado tiempo no hubo variación en el valor máximo de la información mutua. En el caso que este valor no converja, como se mencionó anteriormente, el algoritmo como condición de diseño interrumpe el proceso a las 2500 iteraciones.

## Resultados

Para el análisis de resultados se utilizaron estudios de diagnóstico cerebrales correspondientes a tres pacientes. Estos estudios fueron obtenidos a través del *Insight Journal Database (Insight)* y corresponden a un estudio de tomografía computada (CT) y otro de tomografía por emisión de positrones (PET) por paciente.

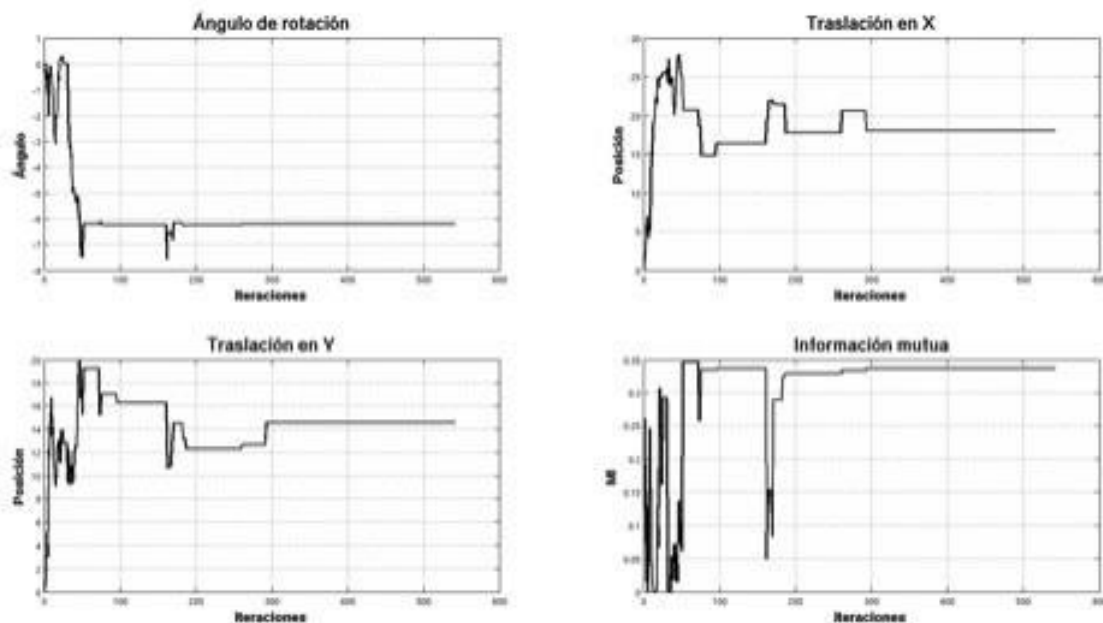
Durante la ejecución del algoritmo en los tres casos se llegó al valor máximo de la información mutua en un tiempo aproximado de 20 segundos con un total entre 500 y 1000 iteraciones.

En la Figura 4 se muestran los gráficos correspondiente a la evolución de los parámetros de la matriz de transformación  $M$  durante el proceso de registración de los estudios del Paciente 1. La Figura 4a) exhibe todos los parámetros *testeados* por el algoritmo y en la Figura 4b) aquellos que fueron aceptados por su valor de  $MI$ . En la gráfica de los valores aceptados correspondiente a la información mutua (Figura 4b))



(a) Todos los parámetros obtenidos





**(b) Parámetros aceptados**

**Fig.4. Información mutua y parámetros de rototraslación correspondiente a los estudios del paciente 1** (Fuente: Elaboración propia)

se puede observar que a partir de la iteración 301 se mantiene, donde además los cambios en la *MI* desde la iteración 200 son despreciables. Por esta razón la condición de la derivada de *MI* permite identificar esta zona y finalizar el proceso de registración.

En la Tabla 2 se muestran los resultados obtenidos durante la registración para cada uno de los estudios evaluados. Como se mencionó anteriormente, los tiempos de cálculo fueron entre 10 y 20 segundos llegando a unas 1000 iteraciones dependiendo del estudio.

El valor máximo *de MI de referencia* que figura en Tabla 2 se obtiene a partir de aplicarle diferentes variaciones a la matriz de transformación *M* y calcular el valor máximo de la información mutua entre dos imágenes. En este caso, se realiza una transformación de traslación de a 1 pixel hasta completar el tamaño de la imagen

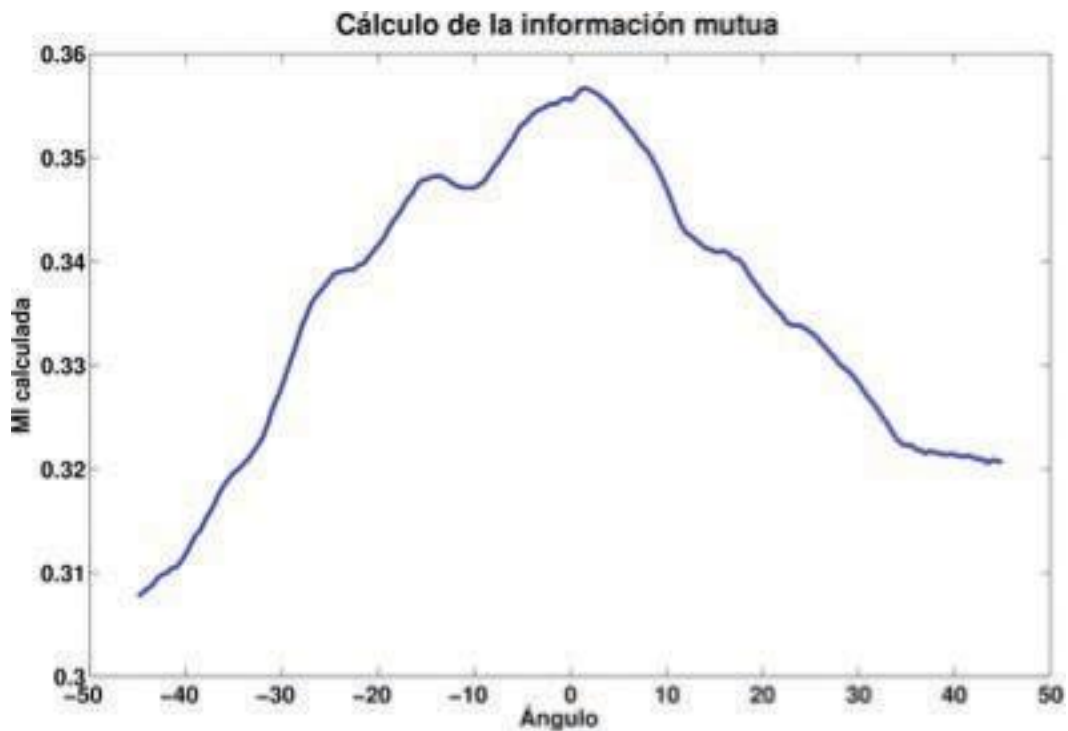
y medio grado en la rotación de  $-45^\circ$  a  $45^\circ$ , donde se obtiene una matriz de *MI* de tamaño  $512 \times 512 \times 181$ , ya que son  $512 \times 512$  traslaciones por cada rotación. Este proceso demanda varias horas de cálculo. Esta búsqueda exhaustiva se realizó para obtener un valor de referencia con el propósito de validar el algoritmo iterativo de registración.

En la Figura 5a) se muestra el valor máximo para cada uno de los 181 ángulos de rotación calculados en el Paciente 1, y en la Figura 5b) los valores de información mutua en función de la traslación en *X* e *Y* para el ángulo que presenta su máximo valor en Figura 5a). Se puede observar que el ángulo en el cual la información mutua es máxima se encuentra en  $1,5^\circ$  con un valor de 0,3567. El mapa de colores va desde el *azul* hasta el *rojo*, indicando desde los valores de *MI* bajos hacia los altos respectivamente.

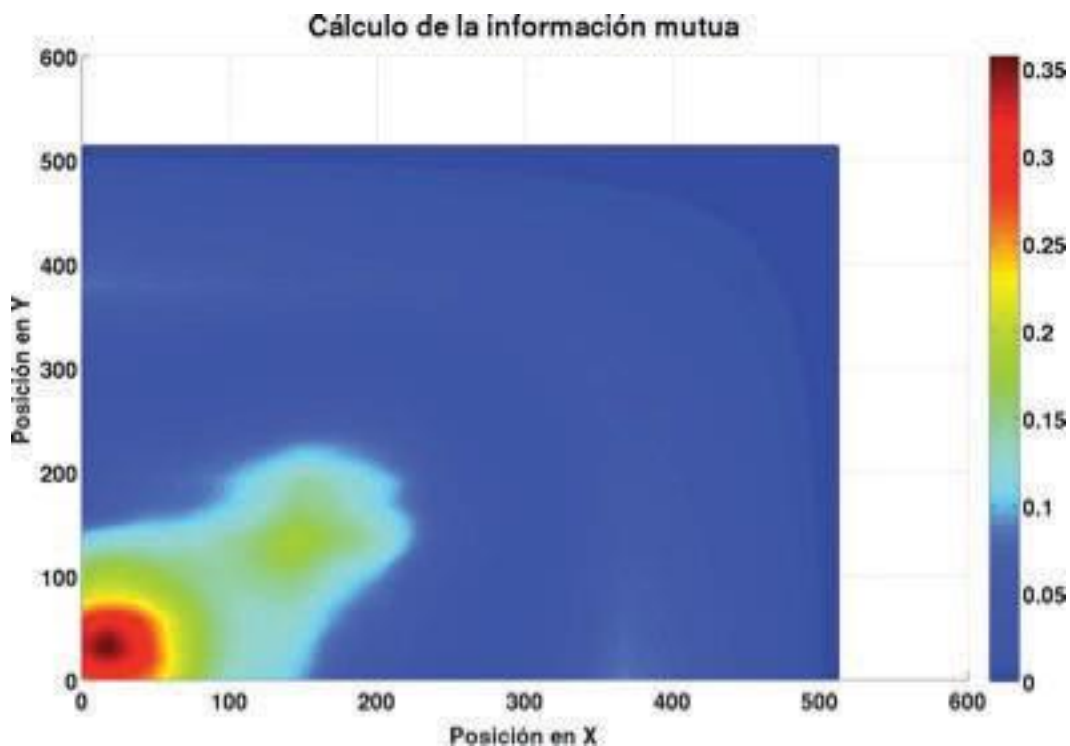
Paciente	Tiempo (seg.)	Iteraciones	máximo <i>MI</i> obtenido	máximo <i>MI</i> de referencia
1	10,4065	542	0,3367	0,3567
2	16,1634	855	0,3525	0,3648
3	17,9433	912	0,2637	0,3045

**Tabla 2. Métricas obtenidas durante la registración de imágenes**

(Fuente: Elaboración propia)



(a) Máximo valor de la información mutua para cada ángulo de rotación




(b) Valores de información mutua en función de la posición

**Fig.5. Cálculo de la información mutua para el Paciente 1**  
(Fuente: Elaboración propia)


Finalmente, en las Figura 6 a-f) se observa la registraci3n realizada para los tres pacientes, donde las m3tricas se encuentran en la Tabla 2. Cada imagen muestra estudios de diagn3stico

cerebral, donde el color *magenta* corresponde al estudio de la tomograf3a computada (CT) y el verde a la tomograf3a por emisi3n de positrones (PET).




(a) Paciente 1: no registradas

(b) Paciente 1: registradas



(c) Paciente 2: no registradas

(d) Paciente 2: registradas



(e) Paciente 3: no registradas

(f) Paciente 3: registradas

## Conclusiones

Durante el desarrollo del presente trabajo siempre se optó por elegir una técnica de registración compatible con imágenes multimodales. El uso de información mutua como métrica fue la que produjo mejores resultados. En la última década se han publicado diversos trabajos relacionados con el uso de esta métrica obteniéndose resultados muy positivos respecto a otras técnicas, como por ejemplo la correlación o error cuadrático medio (Kim, Fessler 2004; Vs, Revathy 2008).

En función de los resultados obtenidos el algoritmo presenta cierta robustez en cuanto a la registración en el modo multimodal (CT y PET), pero aún le queda un camino por recorrer respecto a la optimización de tiempo si se compara con otras técnicas existentes. Uno de los puntos clave de este algoritmo es la búsqueda

del gradiente de la información mutua respecto a la matriz de transformación geométrica. Este paso requiere la estimación de la función de probabilidad conjunta entre las imágenes. En el presente trabajo fue resuelto a partir del método iterativo Metrópolis, el cual muestra muy buenos resultados resolviendo todo el proceso de registración en unos pocos segundos.

Como trabajo a futuro se tiene previsto mejorar la estimación del valor máximo de información mutua y agregar técnicas de transformaciones geométricas afines como transvección y cambio de escala. Posteriormente con el propósito de mejorar los tiempos de procesamiento se realizará una implementación en C++ y utilizando Unidades de Procesadores Gráficos (GPU) en lenguaje CUDA de NVIDIA. Finalmente se realizará una extensión a imágenes en tres dimensiones.

## Referencias

- MAINTZ, J. A.; VIERGEVER, M. (1998). A survey of medical image registration. *Medical Image Analysis*, Volume 2, Number 1.
- WYAWAHRE, M. V.; PATITL, P. M.; ABHYANKAR, K. (2009). Image Registration Techniques: An overview. *International Journal of Signal Processing, Image Processing and Pattern Recognition* Vol. 2, No.3.
- CHUMCHOB, N.; CHEN, K. (2009). A robust affine image registration method. *International Journal of Numerical Analysis and Modeling*, Volume 6, Number 2, Pages 311–334.
- KOSTELEK, P. J.; PERIASWAMY, S. (2003). Image Registration for MRI. *Modern Signal Processing MSRI Publications*, Volume 46.
- VIOLA, P.; WELLS III, W. (1997). Alignment by Maximization of Mutual Information, *International Journal of Computer Vision*, 24(2) pp 137–154.
- BEICH, I.; SULLIVAN, F. (2000). The Metropolis Algorithm, *IEEE Computational Science & Eng.*, Volume 2, pp 65-69.
- SECYT FRBA (2011). AR-PET: Tomografía por Emisión de Positrones <http://www.secyt.frba.utn.edu.ar/gia/pet.html>
- FCDN (2014). Técnicos argentinos desarrollaron el primer Tomógrafo por Emisión de Positrones fabricado en Latinoamérica <http://bit.ly/1TTQHfc>
- CARO, F. (2004). Aplicación de las técnicas de la Teoría de la Información en el registro de Imágenes Médicas. XIII Seminario de Ingeniería Biomédica, Facultades de Medicina e Ingeniería, Univ. de la República Oriental del Uruguay.
- SANDER, E; WOOTTHON J. T.; ALLESINA S. (2015). Mutual Information Venn Diagram for 5-species partitions A and B. Fig\_2.tif, *PLOS Computational Biology*, 10.1371/journal.pcbi.1004330.g002. INSIGHTInsight Journal Database, [http://www.insight-journal.org/rire/download\\_data.php](http://www.insight-journal.org/rire/download_data.php)
- KIM, J.; FESSLER J. A. (2004). Intensity-based Image Registration using Robust Correlation Coefficients. *IEEE Transactions on Medical Imaging*, Volume 23, Issue 11, Pages 1430-1444.
- VS, R.; REVATHY, K. (2008). Using mutual information and cross-correlation as metrics for registration of images. *Journal of Theoretical and Applied Information Technology*, Volume 4, Number 6.