Estado del Arte de la Alineación de Imágenes Médicas e Implementación del Algoritmo de Alineación clásico basado en la Información Mutua

Doctorando: Santiago Murillo Pavas

Directores:

Isabel Navazo Alvaro Álvar Vinacua Pla

Reporte de Investigación

Departament de Llenguatges i Sistemes Informàtics Universitat Politècnica de Catalunya

31 de mayo de 2005

Índice general

1.	Intr	oducción	1		
2.	Estado del Arte 3				
	2.1.	Clasificación de los algoritmos de alineación	3		
	2.2.	Conclusiones	6		
3.	Marco Teórico de la Información Mutua.				
	3.1.	Información Mutua	8		
	3.2.	Entropía	9		
		3.2.1. Estimación de los valores de las distribuciones de pro- babilidad conjunta y marginal	10		
	3.3.	Propiedades de la información mutua	10		
4.	Aplicación del Algoritmo de Alineación Usando Información Mutua Como Medida de Similitud				
	4.1.	Pseudocódigo del algoritmo propuesto	13		
	4.2.	Información de entrada y preproces o $\ \ldots\ \ldots\ \ldots\ \ldots\ \ldots$	13		
	4.3.	Prealineación	14		
	4.4.	Optimización	14		
		4.4.1. Transformación	15		
	4.5.	Transformación final y Visualización de Resultado	17		
5.	\mathbf{Res}	ultados	18		
	5.1.	Resultados del algoritmo de alineación aplicado a Imágenes CT	18		
	5.2.	Resultados del algoritmo de alineación aplicado a Imágenes SPECT	20		

5.3	3. Conclusiones sobre los resultados:	• • • •	. 22
6. Co	Conclusiones Generales y Trabajo Futuro		24

Resumen

La alineación de imagines cardíacas procedentes de imágenes de medicina nuclear tal como la Tomografía Computarizada por Emisión Única de Positrones (SPECT) constituye un campo de investigación activo dada su importancia en el diagnostico de cardiopatías. En este reporte presentamos el estado del arte de la alineación de imágenes médicas con énfasis en la alineación de imágenes cardíacas al igual que una aplicación del método de alineación para imágenes SPECT cardíacos usando la información mutua como medida de similitud.

Cardiac images registration coming from nuclear medicine like Single Positron Emition Computer Tomography (SPECT) has become an active research field since it is an important tool for the diagnostic of cardiac pathologies. In this report we present the state of the art of medical image registration with emphasis in cardiac images, likewise it is presented an application for registration of SPECT images using mutual information like similarity measure.

Introducción

La técnica de SPECT (Single Photon Emition Computed Tomographic) es prácticamente imprescindible actualmente para la evaluación de la perfusion en el miocardio, con superioridad demostrada en cuanto a sensibilidad diagnóstica y localización topográfica de las áreas patológicas frente a las imágenes capturadas mediante Tomografía computarizada (CT) o Resonancia Magnética (MR).

El diagnóstico de cardiopatías a partir de imágenes de medicina nuclear se realiza mediante dos posibles comparaciones: comparar la imagen obtenida con un atlas de la distribución de intensidad ideal (comparación externa) o comparar la imagen en esfuerzo con la imagen reposo (comparación interna). En ambos casos las imágenes requieren ser alineadas a efectos de comparar las mismas regiones del miocardio. Esta comparación puede dar lugar a tres tipos de fenómenos:

- 1. La distribución de la intensidad es normal en ambas imágenes
- 2. Hay regiones con un poco de anormalidad en ambas imágenes, que puede denotar desórdenes en la perfusion sanguínea.
- 3. Hay una o mas regiones con baja densidad en la imagen en esfuerzo pero con normalidad en la imagen de reposo, que puede denotar una isquemia en esfuerzo.

Para la adquisición de las imagen SPECT se requiere administrar previamente un marcador con un radioisótopo emisor de fotones gamma. La adquisición se basa en obtener múltiples imágenes gammagráficas o proyecciones planares desde todos los ángulos posibles alrededor del torso. A partir de esas imágenes, el ordenador del tomógrafo reconstruye, por retroproyección filtrada o por métodos iterativos, el volumen del corazón, que se representa mediante cortes, sucesivas secciones paralelas definiendo cada una un plano en el espacio.

Las imágenes SPECT tienen características diferentes respecto a las imágenes diagnosticas no nucleares en cuanto a su resolución, al nivel de ruido y a los valores de intensidad. Las imágenes con las que se realizaron las pruebas provienen de una gammacámara de 2 cabezales con una resolución de 64x64 pixeles, donde cada pixel representa un área de 6,614x6,614 mm, frente a una resolución de una imagen CT del orden de 256x256 pixeles donde cada pixel representa un área de 0,23x0,23 mm.

Debido a esta diferencia de información contenida en los tipos de imágenes mencionados, no es evidente que el algoritmo de alineación usado para imágenes CT y MR sea directamente aplicable al caso SPECT.

En este reporte, en el capitulo 2, se sintetizan los métodos de alienación de imágenes médicas (generalmente aplicados a imágenes CT o MR) a partir de lo cual se concluye cuales pueden ser adecuados para el caso de alienación de imágenes SPECT. En el capitulo 3 se presenta el marco teórico del tipo de algoritmo seleccionado, el cual se basa en la Información Mutua como medida de similitud. En el capitulo 4 se implementa el algoritmo propuesto por autores como A. Collignon[3], P.Viola en [21] y J. Pluim[16], aplicándolo tanto a imágenes CT como SPECT. En el capitulo 5 se evalúan los resultados obtenidos se concluye con las modificaciones necesarias para su aplicación y adaptación al caso SPECT

Estado del Arte

A continuación se hace una revisión de los algoritmos propuestos para la alineación de imágenes médicas.

2.1. Clasificación de los algoritmos de alineación

Los métodos propuestos hasta ahora tienen multiples enfoques que van desde la comparación por seguimiento de puntos marcados correspondientes a sitios anatómicos geométricos, la alineación basada en segmentación de modelos rígidos (puntos, curvas y superficies) o modelos deformable (snakes, nets) y la alineación basada en propiedades de voxels, como la alineación de ejes principales y usando el contenido total de la información de la image.

- 1. *Extrínseco:* Se refiere a la intervención del paciente antes de la captura de las imágenes.
 - a) Invasivo: Se inserta un objeto al paciente (cerca del órgano de interés), este tipo de métodos es expuesto por Vandermeulen et al en [6].
 - b) No- invasivo: Adherir objetos a la piel para luego alinear el objeto en cada imagen diagnóstica. Método expuesto por Wang et al en [22]
- 2. Intrínseco: Se refiere a las características de la imagen.
 - a) Basados en puntos de referencia: método basado en la selección de puntos por el usuario para luego hacer la alineación de esos puntos minimizando la distancia entre el punto trasformado y su punto correspondiente en la imagen de referencia. Este método es aplicable a cualquier tipo de imágenes y en especial cuando se

quieren encontrar transformaciones rígidas. Si existe un número considerable de puntos podría emplearse para hallar trasformaciones mas complejas. El método tiende a caer en óptimos locales, se pueden diferenciar dos formas de seleccionar los puntos de referencia:

- 1) Anatómicos: seleccionando puntos importantes de la fisiología visible para luego ubicarlos en las dos imagenes y hacer la correspondiente alineación, este método lo presentan Maintz et al y Evans et al en [11] y en [7]respectivamente.
- 2) Geométricos: seleccionar puntos de características notables geométricamente como puntos de maxima curvatura o esquinas, estos puntos pueden ser localizados de forma automática, método propuesto por Christensen en [2]
- b) Basado en segmentación: la segmentación en este caso se refiere a la selección de estructuras dentro de la imagen con mayor complejidad como curvas, superficies y volúmenes. En este tipo de métodos existen dos enfoques: el empleo de modelos rígidos y el uso de modelos deformables
 - Modelos rígidos: consiste en seleccionar puntos, curvas, superficies de ambas imágenes para luego alinearlas de forma independiente, la transformación resultante es aplicada a las imágenes originales de forma global, este enfoque fue presentado por Declerkc et al en [5]
 - 2) Modelos deformable: en este enfoque una imagen debe deformarse elásticamente para ajustarse a la otra imagen, para esto Davatziko et al [4] usan sólidos deformables (nets) y curvas deformables (Snakes), la optimización en este caso siempre es local y su precisión depende de la precision del método de segmentación que por lo general se hace de forma semi-automática.
 - 3) Segmentación basada en Información mutua: este enfoque fue presentado por J.Rigau et al [17], en su propuesta se segmenta cada imagen en celdas rectangulares de forma iterativa en un proceso "bottom-up" hasta obtener una segmentación intermedia que contenga la mayor información promedio en todas las celdas, la segmentación final se encuentra modificando el histograma de intensidad mediante el agrupamiento de valores vecinos, de tal forma que la reducción en la información mutua antes hallada sea minima. las imágenes segmentadas sirven de datos de entrada al proceso de alineación usando un indicador normalizado de la información mutua entre las dos imágenes.

- c) Métodos Basado en propiedades de voxel: estos métodos operan sobre los valores de propiedad en la imagen. Hay dos enfoques, el primero es reducir los valores de propiedad a conjuntos representativos de escalares y orientaciones, la segunda es usar todo el contenido de la imagen en el proceso de alineación.
 - Reducción a escalares o vectores (orientaciones, escalares, ejes principales): se calcula el centro de gravedad de la imagen y las direcciones a partir de los momentos de orden cero y uno, este enfoque es usado por Pavia et al y Slomka et al en [14], [19] respectivamente.
 - 2) Métodos que Usan todo el contenido de la imagen: los métodos de alineación enmarcados en esta aproximación ofrecen un atractivo importante para el problema al que nos enfrentamos, toda vez que usa toda la información disponible de la imagen. Anteriormente no era imaginable su aplicación dado el alto costo computacional, sin embargo, con el aumento de la capacidad del hardware actual es posible implementar algoritmos de este tipo con relativa eficiencia y resultados mas precisos, además este método es aplicable a cualquier tipo de imágenes.

Las medidas de similitud mas usadas para este tipo de algoritmos son:

- a' Correlación cruzada: medida usada por Studholme et al en [20].
- b' Minimizar la varianza en radios de intensidad: método usado por Zuo en [23].
- c' Minimizar la entropía del histograma conjunto de intensidad: método usado por Buzu et al en [1].
- Maximizar la Información Mutua, este indicador de d'similitud cobra cada vez mas importancia, fue introducida por Collignon et al [3], para la alineación multimodal de imágenes (MR-CT) cerebrales; por otro lado Chen et al [8] han usado la información mutua para la alineación de imágenes CT-MT y CT-PET del cerebro, Viola [21] ha usado información mutua para alineación de imágenes 2D-3D combinado trasformadas globales y modelos deformables locales. Pluim et al [9], [15], [16] han usado información mutua para alineación de imágenes cerebrales multimodales. J.Rigau et al [17] alinean imágenes CT y MR usando el indicador normalizado de la información mutua y parten de imágenes segmentadas como se mencionó en los algoritmos basados en la segmentación. Hasta la fecha no hay publicada una propuesta del uso de la in-

formación mutua para la alineación de imágenes SPECT cardíacas.

- e' Minimizar la diferencia absoluta o cuadrada de intensidades: indicador usado por P.J. Slomka et al [19].
- f' Alineación de las expansiones de Taylor determinadas por los valores de gris de las imágenes, enfoque presentado por K. Shields et al en [18]
- 3. Métodos no basados en la imagen: Se basan en la alineación de las coordenadas de los instrumentos de captación de la imagen, bajo el supuesto que el paciente esta ubicado en la misma precisión relativa y no hay un movimiento en la toma (supuestos difíciles de cumplir!). Este tipo de alineación se ha usado en imágenes procedentes de ultrasonido ya que el equipo esta equipado con un sistema de localización espacial que puede ser fácilmente calibrado y usado cuando el paciente es inmovilizado en la mesa grúa. Esta técnica de calibración del sistema de coordenadas es usado también en la alineación de posiciones de las herramientas de cirugía montadas en un brazo robótico.

2.2. Conclusiones

Retomando el caso que nos ocupa, la alineación monomodal de imágenes SPECT, concluimos que:

- Se descarta el uso de métodos de alineación extrínseco ya que no es viable para el caso, requeriría una intervención quirúrgica.
- De los métodos Intrínsecos se descartan los métodos basados en puntos de referencia y los basados en segmentación debido a que en una imagen SPECT pueden no aparecer puntos que en otra si aparecen debido a la ausencia de riego sanguíneo en la region del miocardio representada por dichos puntos o estructuras.
- Los métodos intrínsecos basados en propiedades de voxeles son los que consideramos mas apropiados para la alineación de imágenes SPECT, en especial aquellos que hallan una medida de la relación o solapamiento de las dos imágenes con un enfoque global, de las meditadas de similitud usadas en estas aproximaciones, la información mutua es más robusta en comparación a medidas como la correlación o la entropía conjunta de las imágenes, aunque no ha sido probada su aplicabilidad a la alineación de imágenes SPECT, la cual se hace hasta ahora con intervención activa del usuario.

- Los métodos no basados en la imagen no son aplicables, dado que no se puede garantizar la equivalencia de los sistemas de coordenadas en ambas captaciones.
- Un método de alienación esta compuesto por dos partes principales, la medida de similitud y el tipo de optimización, La medida de similitud seleccionada es la Información Mutua, el tipo de optimización se describe en el capitulo 4.

Marco Teórico de la Información Mutua.

A continuación se presentan los conceptos teóricos esenciales para la comprensión de la medida de similitud seleccionada.

3.1. Información Mutua

La información mutua como medida de similitud se ha empleado en los algoritmos propuestos por: Chen [8], Colling[3], Maes [10], Makela [13], Mayer [12], Pluim [15] y Viola [21] para la alineación multimodal de imágenes procedentes de CT, MR y PET.

En imágenes la información mutua (I(A, B)) se interpreta como la medida de la información que contiene una imagen flotante A. con respecto a una imagen de referencia B. Matemáticamente I(A, B) se define como:

$$I(A,B) = H(A) + H(B) - H(A,B)$$

O bien la definición en forma normalizada.

$$I(A,B) = \frac{H(A) + H(B)}{H(A,B)}$$

Donde: H(A) y H(B) denotan las entropías de las imágenes A y B respectivamente, entendiendo como entropía la medida de la variación en los valores de intensidad de la imagen. Por analogía H(A, B) es la medida de la variación de los valores de intensidad de la imagen B con respecto a la imagen A.

Esto se puede apreciar en la figura 3.1, si a la suma de las variaciones independientes se resta la variación de una imagen con respecto a la otra el resultado será la información mutua entre las dos imágenes.



Si la información contenida en las dos imágenes son iguales, el valor de la información mutua es la entropía de la imagen. Por tanto el rango de la información mutua es: $0 \le I(A, B) \le H(A)$, toda vez que en una alineación ideal se cumple que H(A) = H(B) = H(A, B).

La alineación de las imágenes sera óptima cuando el valor de I(A, B) esté más cerca de su valor máximo, lo que significará que se alcanza la máxima dependencia entre las dos imágenes.

3.2. Entropía

En el algoritmo se utiliza la definición de entropía de Shannon usada en el campo de teoría de señales, la cual consiste en medir la cantidad de información presente en una señal, formalmente su definición es:

$$H(A) = \sum_{a \in A} p(a) \log p(a)$$
$$H(B) = \sum_{b \in B} p(b) \log p(b)$$

De forma análoga:

$$H(A,B) = \sum_{a \in A} \sum_{b \in B} p(a,b) \log p(a,b)$$

Donde $p(a) \neq p(b)$ son los valores de las distribuciones marginales de probabilidad para el valor a de la imagen A y el valor b de la imagen B respectivamente y p(a, b) es el valor de la distribución de probabilidad conjunta para los valores de intensidad $a \neq b$.

3.2.1. Estimación de los valores de las distribuciones de probabilidad conjunta y marginal

El estimador de la distribuciones de probabilidad conjunta se calcula mediante la normalización de cada entrada del histograma conjunto de los valores de intensidad de las imágenes A y B.

El estimador de las distribuciones de probabilidad marginal de los valores de intensidad de las imágenes A y B se calculan a partir de la suma por filas y por columnas del histograma conjunto normalizado.

Las expresiones analíticas para el calculo de los valores de distribuciones de probabilidad conjunta p(a, b) y marginal p(a), p(b), son:

$$p(a,b) = \frac{h(a,b)}{\sum_{a,b} h(a,b)}$$
$$p(a) = \sum_{b} p(a,b)$$
$$p(b) = \sum_{a} p(a,b)$$

3.3. Propiedades de la información mutua

La información mutua tiene las siguientes propiedades teóricas:

1. I(A, B) = I(A, B).

La información mutua es simétrica.

- I(A, A) = H(A)
 La cantidad de información de la imagen A con respecto a si misma es igual a la entropía de A.
- 3. $I(A, B) \le H(A), I(A, B) \le H(B)$
- 4. $I(A,B) \ge 0$

5. Si A y B son independientes, entonces I(A, B) = 0 Esto es, la información que contiene una con respecto a la otra es nula.

Aplicación del Algoritmo de Alineación Usando Información Mutua Como Medida de Similitud

La implementación de este algoritmo de alineación se realiza con el propósito de evaluar la aplicabilidad de la alineación basada en información mutua al caso de imágenes SPECT, dado que no es evidente su utilidad debido a las características de las imágenes SPECT (poca resolución y presencia significativa de ruido)

A continuación se describe el algoritmo de alineación global de imágenes basado en información mutua. A modo general este algoritmo se caracteriza por:

- Preproceso de las imágenes
- Prealienación
- Uso de trasformaciones rígidas
- Proceso de optimización heurístico basado en la búsqueda multidirectional de Powell en combinación con el método de Brent.
- Calculo de información mutua en cada trasformación probada en el proceso de optimización, usando toda la información contenida en la imagen

A continuación se describe le pseudocódigo del algoritmo de alineación de imágenes.

4.1. Pseudocódigo del algoritmo propuesto

- 1. Información de entrada y preproceso
 - a) Lectura de imágenes procedentes de una capa especifica de la captación SPECT.
 - b) Estandarización del rango de valores de intensidad.
 - c) Aplicación de un filtro Kernell Gaussiano.
- 2. Prealineación: alineación de baricentros.
- 3. Optimización de los parámetros de trasformación

Definición del tamaño de paso de la búsqueda heurística: Para cada uno de los 3 parámetros de trasformación

Mientras el Tamaño de paso sea mayor a un limite fijado y el numero de iteraciones sea menor al número máximo

Calcular información mutua inicial.

Calcular información mutua en los extremos del intervalo de búsqueda I_1 e I_2

si $I_1 \vee I_2 > I_0$ entonces actualizar valor de los parámetros

si no Reducir tamaño de paso

Incrementar en 1 el numero de Iteraciones fin Mientras

4. Transformación final y Visualización de Resultado: Aplicar parámetros óptimo a la imagen flotante y mostrarlos en pantalla.

4.2. Información de entrada y preproceso

El algoritmo parte de dos imágenes a alinear. Una de ellas se etiqueta como imagen flotante y la otra como imagen de referencia. Al ser la información mutua el indicador de similitud, y dado que su medición se basa en el histograma conjunto de intensidad, se debe tener algunas consideraciones para optimizar el funcionamiento del algoritmo, como son:

1. Estandarización de los valores de intensidad de las imágenes, ambas se llevan a un rango entre 0 y 255.

2. Se aplica un filtro con kernel gaussiano de radio 5, con el fin de suavizar el gradiente de intensidad y disminuir los errores de alineación por los cambios introducidos en la interpolación y el efecto subpixel. Este filtro es estrictamente necesario en caso de alineación multimodales y recomendable en todos los casos con el fin de disminuir los errores de alineación por pequeñas diferencias entre los valores de intensidad que representan la misma región, esta apreciación es común a los autores: Colling [3], Viola [21] y J.Pluim [15].

El filtro aplicado es:

$$KG = \frac{1}{115} \cdot \begin{vmatrix} 2 & 4 & 5 & 4 & 2 \\ 4 & 9 & 12 & 9 & 4 \\ 5 & 12 & 15 & 12 & 5 \\ 4 & 9 & 12 & 9 & 4 \\ 2 & 4 & 5 & 4 & 2 \end{vmatrix}$$

4.3. Prealineación

Se alinean ambas imágenes en una traslación equivalente a la diferencia entre sus respectivos baricentros como punto de partida para hallar la solución optima final.

Calculo de baricentros: siendo $V_{i,j}$ el valor de intensidad en el pixel(i, j) con origen en (x, y) y SV la suma de los valores de intensidad normalizado de cada imagen, las coordenadas del baricentro (X, Y) se calculan como:

$$X = \frac{\sum_{i,j} V_{i,j} * x_{i,j}}{SV}$$
$$Y = \frac{\sum_{i,j} V_{i,j} * y_{i,j}}{SV}$$

4.4. Optimización

Se usa el método multidireccional de Powell para maximizar la información mutua, en combinación con el algoritmo de optimización unidimensional de Brent para hallar el óptimo de cada parámetro.

El método de Powell realiza un optimización a la vez para cada parámetro de la transformación (una dimensión del espacio de búsqueda a la vez), la posición final de un parámetro es el punto de partida para hallar el óptimo del siguiente parámetro.

El método de Brent sigue una parábola que debe "escalar" hasta encontrar el valor máximo, reduciendo el tamaño de paso especificado y por tanto el intervalo de búsqueda cada vez que en ambos extremos del intervalo se encuentran valores de la función objetivo menores al valor de dicha función en el valor actual del parámetro. En caso de encontrar un valor mayor en uno de los extremos se actualizará el valor del parámetro al extremo del intervalo repitiendo la prueba. El proceso de optimización de cada parámetro termina cuando se alcanza un número máximo de iteraciones o hasta que el tamaño de paso se reduce a un limite establecido.

El orden en que se realiza la optimización puede afectar la solidez de la optimización. En el caso particular del SPECT, se seleccionó como orden (θ, t_x, t_y) toda vez que se hace una alineación de baricentros inicialmente, de otra forma sería necesario la aplicación del algoritmo de optimización dos veces: la primera con el orden (t_x, t_y, θ) y la siguiente con el orden (θ, t_x, t_y) . La mejora de los resultados aplicando la optimización una segunda vez no supera el pixel como se muestra en el capitulo 5, Resultados.

4.4.1. Transformación

En cada iteración de la optimización son calculados tres valores del indicador de información mutua correspondientes a la imagen flotante trasformada con los parámetros de prueba de la iteración.

En el enfoque comúnmente usado la transformación utilizada es una transformación geométrica rígida compuesta de traslación y rotación, al cual se define como: T_{α} con $\alpha = (\Theta, \Delta x, \Delta y)$, donde Θ es el ángulo de rotación con respecto al baricentro de la imagen y Δx y Δ las traslaciones con respecto a los ejes coordenados X e Y.

Esta transformación se aplica recursivamente hasta encontrar aquella que genere la imagen que mejor se alinea con la imagen de referencia (maxima información mutua). Los parámetros óptimos α^* son hallados a partir de

$$\alpha^* = \arg \max_{\alpha} I(\alpha)$$

Si S denota la malla de la imagen flotante original y S' las la malla de la imagen flotante resultante de la transformación; las coordenadas $(x', y') \in S'$ correspondientes al punto $(x, y) \in S$ son definidas por:

$$x' = \cos \theta \cdot x - \sin \theta \cdot y + \Delta x$$
$$y' = \sin \theta \cdot x + \cos \theta \cdot y + \Delta y$$

En general la rejilla de la imagen resultante de una trasformación de la imagen flotante A no coincide con la rejilla de la imagen de referencia B, por

tanto es necesaria una interpolación para obtener los valores de intensidad resultantes.

Interpolación para la trasformación de la imagen flotante

La elección del método de interpolación es de suma importancia ya que afecta directamente la información de la imagen, los tipos de interpolación mas comunes en trasformaciones geométricas son la interpolación al vecino mas proximo y la interpolación bilineal. La interpolación al vecino más próximo puede producir perdida de valores al asignar dos valores a un mismo pixel, la interpolación bilineal puede introducir valores que antes no se encontraban en la imagen flotante original provocando cambios imprevisibles en la distribución de probabilidad marginal de la imagen flotante P(A)así como cambios en la distribución de probabilidad conjunta y por ende en la información mutua. Para disminuir este efecto se emplea la Interpolación Parcial Volumétrica (IPV), introducida por Collignon95[3] y descrita en detalle y ampliada en Chen03[8]. La IPV en lugar de interpolar nuevos valores de intensidad, calcula la contribución de la intensidad de la imagen A(s) al histograma conjunto distribuyéndola sobre las entradas del histograma conjunto correspondientes a los cuatro vecinos mas próximos en la imagen original, usando los mismos pesos que usa la interpolación trilineal, de este modo el histograma cambia suavemente cuando los parámetros (α) varían.

La figura 4.4.1 muestra la IPV.



IPV

El histograma conjunto de intensidad es entonces calculado como:

$$h(a,b) = \sum_{i=1}^{4} \Sigma \omega_i$$

donde:

$$\omega_1 = (1 - \Delta_x) \cdot (1 - \Delta_y)$$
$$\omega_2 = \Delta_x \cdot (1 - \Delta_y)$$
$$\omega_3 = \Delta_x \cdot \Delta_y$$
$$\omega_4 = (1 - \Delta_x) \cdot \Delta_y$$

4.5. Transformación final y Visualización de Resultado

En este ultimo paso se toman los parámetros óptimos hallados por la optimización y se aplican a la imagen flotante, La visualización dependerá de las necesidades de cada usuario.

Resultados

Las pruebas realizadas fueron efectuadas sobre imágenes 2D procedentes de archivos tipo DICOM, de captaciones CT y SPECT. La mayoría de las pruebas se efectuaron construyendo una imagen sintética flotante a partir de la transformación rígida T_{α} de la imagen de referencia a fin de controlar los parámetros objetivos y medir la precisión del algoritmo. Se esperaría que el algoritmo de optimización retorne como óptimo los parámetros de la transformación inversa a la trasformación inicial.

Las imágenes CT tienen una resolución de 256 x 256 pixeles y las imágenes SPECT una resolución de 64 x 64 pixeles. Las rotaciones se realizaron alrededor del baricentro de la imagen.

Los resultados presentados son la síntesis de las pruebas mas relevantes hechas sobre el algoritmo.

5.1. Resultados del algoritmo de alineación aplicado a Imágenes CT

El objetivo de esta prueba es validar el funcionamiento de la aplicación con el tipo de imágenes con las cuales se ha empleado el algoritmo.

Las imágenes proceden de tres modelos CT, modeló maxilofacial, modelo del tórax (Hígado) y modelo de la cabeza. Se usaron 3 capas de cada modelo, las capas número 9,12,19. La imagen construida a partir de la capa n de la captación es etiquetada como imagen de referencia y la imagen flotante se construye a aplicando una trasformación rígida a la imagen de referencia con el fin de controlar la trasformación esperada y evaluar la precisión del algoritmo, con cada capa se realizaron 4 pruebas variando los parámetros de generación de la imagen de flotante, esto es, para el ángulo de rotación se usaron valores en el rango $0;\Theta;180$, par las traslaciones en X e Y se usaron

	Maxilofacial	Tórax	Cerebral
Precisión en	(0.56, 0.353, 0.896)	(0.5, 0.333, 0.667)	(0.83, 0.16, 0.28)
parámetros			
$(\Theta, \Delta X, \Delta Y)$			
Desviación	(0.752, 0.516, 0.816)	(0.749, 0.520, 0.786)	(0.727, 0.547, (0.516))
estándar de la			
precisión			
Tiempo de	231.5	318.33	382.42
Optimización			
promedio (s)			
Número de	244.56	256.78	328.42
iteraciones to-			
tales promedio			

Cuadro 5.1: Resultados para Imágenes CT

valores en el rango 0¡X e Y ¡40.

Como criterios de parada de la optimización descrita en el capitulo 4 se usan el número máximo de iteraciones y un limite inferior en el tamaño de paso. Dado que el método de optimización de Powell hace la optimización de cada parámetro a la vez, el número máximo de iteraciones se fija en 100 iteraciones para el ángulo Θ y 80 para cada uno de los parámetros de traslación, para un total de 260 iteraciones máximas, el tamaño de paso inicial se fija en 30 ° para el ángulo de rotación, y en 40 pixels para los parámetros de traslación, como criterio de parada se tiene un tamaño de paso de 1° para el ángulo y de 1 pixel para la traslación. El algoritmo se detendrá si alcanza alguno de los dos primeros, siendo mas deseable que llegue al limite inferior del tamaño de paso, pues esto significaría al convergencia del algoritmo a un óptimo global.

En el cuadro 5.1 se muestra los resultados de las pruebas sobre el algoritmo. La precision relacionada se refiere a la diferencia absoluta promedio entre la trasformación esperada y la obtenida. La medida se realizo para cada uno de los tres parámetros de trasformación ($\Theta, \Delta X, \Delta Y$), donde Θ es el ángulo de rotación, ΔX y ΔY los parámetros de traslación en X e Y respectivamente.

Los resultados de la tabla 5.1nos permiten concluir que tal como lo exponen los autores que han usado el algoritmo de alineación de imágenes basado en información mutua aplicado a imágenes CT, Chen [8], Colling[3], Maes [10],Makela [13], Mayer [12], Pluim [15] y Viola [21]; el algoritmo de alineación obtiene una precision promedio subpixel cuando es aplicado a imágenes CT, y su comportamiento es robusto dado que no mostró ningún resultado a típico como lo indica la desviación estándar de la precisión.

La figura 5.1 muestra la capa 12 de cada captación CT usado en las pruebas



En la figura se presenta en color rojo las imágenes flotante y de referencia, y la tercera fila de cada columna corresponde a la visualización conjunta de la imagen flotante final en canal verde y la imagen de referencia ne canal rojo, el color amarillo corresponde a los pixeles alienados.

5.2. Resultados del algoritmo de alineación aplicado a Imágenes SPECT

El objetivo de esta prueba es validar la aplicabilidad del algoritmo a la alineación de imágenes SPECT cardíaco.

Las imágenes proceden de un modelo Phantom SPECT del ventrículo Izquierdo. Estas fueron extraídas de las capas con valor Z = 7, 12 y 15, las cuales corresponden a los cortes mas representativos del corazón. En total se realizaron 60 pruebas, 10 con cada capa. El algoritmo implementado descrito en el capitulo 4 se aplica con las siguientes especificaciones.

1. Generación de la imagen flotante: se genera a partir de una trasformación rígida determinada aplicada a la capa n de la captación SPECT con el fin de controlar los resultados esperados. Las diferentes trasformaciones aplicadas a las capas fueron valores acorde con las características de las imágenes SPECT, esto es, para el ángulo de rotación:

Cuadro 5.2: Resultados para Imágenes SPECT

Precisión en parámetros	(4.85, 2.56, 3.08)
$(\Theta, \Delta X, \Delta Y)$	
Desviación estándar de la	(11.44, 2.14, 2.02)
precisión	
Tiempo de Optimización	235.43
promedio (s)	
Número de iteraciones to-	646.48
tales promedio	

 $0_i\Theta_i180$, par las traslaciones en X e Y: 0_i X e Y $_i10$. La inversa de dicha trasformación en cada caso será la trasformación optima esperada.

2. Criterio de parada del algoritmo de optimización: se establecen dos criterios de parada simultáneos, el primer criterio es el numero máximo de iteraciones, el cual se fija el 300 iteraciones para el ángulo Θ y 200 iteraciones para cada uno de los parámetros de traslación, para un total de 700 iteraciones máximas. El segundo criterio de parada es el tamaño de paso, cuyo valor inicial se fija en 30 ° para el ángulo de rotación, y en 10 pixels para los parámetros de traslación, como criterio de parada se tiene un tamaño de paso de 1° para el ángulo y de 1 pixel para la traslación, la optimización de un parámetro finalizará cuando alcance uno de los dos criterios. Es deseable que se cumpla se llegue al tamaño de paso mínimo en primer lugar y no al número máximo de iteraciones; en caso contrario no estaría garantizada la convergencia de la optimización a un óptimo global.

En el cuadro 5.2 se muestran los resultados promedio de las 60 pruebas realizada, la precisión indica la diferencia absoluta promedio entre las trasformaciones resultantes y la trasformación esperada. La desviación estándar da una idea de la variabilidad de la precisión.

El cuadro 5.2 muestra unos resultados poco satisfactorios en cuanto a la precision cuando el algoritmo es aplicado a las imágenes SPECT, los peores resultados fueron obtenidos en las pruebas con la capa Z = 7 correspondiente al vértice del ventrículo derecho, es decir la capa con menos información. La alta desviación estándar de la precision en el parámetro correspondiente al ángulo de rotación evidencia la sensibilidad del algoritmo cuando existe poca información y además baja resolución.

Cabe destacar que las pruebas realizadas a partir de una imagen flotante generada sin rotación, dieron buenos resultados, lo que sugiere la amplificación de la interferencia de la interpolación en la alineación en el caso SPECT. En todos los casos probados el algoritmo de optimización realizo menos iteraciones que el número máximo, por lo que se descarta la convergencia del algoritmo a óptimos locales.

En términos de desplazamiento real la precision del algoritmo para el caso SPECT corresponde en promedio a 4pixeles.

La figura 5.2 muestra la capa 12 del modelo phantom SPECT usado en las pruebas



La tercera columna de la imagen 5.2 corresponde a la visualización conjunta de la imagen flotante final en canal verde y la imagen de referencia en canal rojo, el color amarillo corresponde a los pixeles alienados, los pixeles en color verde o rojo corresponden al error de alienación.

5.3. Conclusiones sobre los resultados:

Con base en los resultados obtenidos se concluye:

Las técnicas basadas en la teoría de la información son naturalmente sensibles a la cantidad de información presente en las imágenes.

Las imágenes SPECT no contienen mucha información. Partiendo de una resolución de 64x64 pixeles, la información relevante esta contenida en un area que ronda los 20x20 pixeles, esto, sumado a los efectos de la interpolación en que se cambian los valores de la imagen original podría ocasionar inestabilidad del algoritmo, aunque esto se minimiza al introducir la interpolación parcial volumétrica, no se elimina totalmente dicha sensibilidad.

En los casos de imágenes CT cerebral y CT del tórax, la información tratada reside en casi la totalidad de los 256 X 256 pixeles, siendo la medida de la información mutua de las imágenes mas robusta.

No obstante lo anterior la alineación SPECT cardíaco usando la información mutua como similitud sería una alineación ciertamente mas confiable que la simple alineación de los baricentros y un herramienta útil en comparación con la alineación manual que hasta ahora se hace. Sin embargo su precision es susceptible de mejorar.

Conclusiones Generales y Trabajo Futuro

El algoritmo de alineación retorna la trasformación esperada para el caso de las imágenes CT. Sin embargo para el caso SPECT la precisión hallada de ± 4 pixeles no es suficiente en casos reales de diagnostico de isquemias, más aun si tenemos en cuenta que un solo pixel representa 6,6x6,6 mm en el objeto modelado.

Con el fin de mejorar la precision del algoritmo para el caso SPECT cardíaco es conveniente analizar a profundidad el efecto de la interpolación en el calculo de la trasformación optima y encontrar estrategias que contrarresten la baja resolución de las imágenes SPECT sin cambiar los valores de intensidad que las mismas contienen.

Una vez mejorada la precisión del algoritmo para el caso de alineación SPECT analizará en profundidad una extension del algoritmo al caso 3D buscando la alineación de los modelos volumétricos.

Bibliografía

- T. Buzug96 and J. Weese. Improving dsa images with and automatic algorithm based on template matching and an entropy measure. *Computer Assited Radiology*, 1124:145–150, 1996.
- [2] G. E. Christensen. Consistent linear-elastic trasformations for image matching. *in proc of IPMI'99*, 1613(LNCS):224-237, 1999.
- [3] A. Collignon. Multi-modality medical image registration by maximization of mutual information. PhD thesis, Ctholic University of Leuven, Leuven, Belgium, 1998.
- [4] C. Davatzikos. Nonlinear registration of brain images using deformable models. Mathematical métodos en biomedical image Analayysis, pages 94–103, 1996.
- [5] J. Declerck, j. Feldmar, M. L. Goris, and F. Betting. Automatic registration and alignent on a template of cardiac stress and rest spect images. *IEEE Transaction on MEdical Imaging*, 16(6):727–737, 1997.
- [6] D. Vandermeulen. et al. Multi-modality image registration within covira. Medical Image: Analysis of Multimodality 2D/3D images, 19, 1995.
- [7] A.C. Evans, S. Marrett, L. Collins, and T.M. Peters. Anatomicalfunctional correlative analysis of human brain using three dimensional imaging system. *MEdical Imaging: Image Processing*, 1092:264–274, 1989.
- [8] Chen H. and Varshney P. k. Mutual information-based ct-mr brain image registration using generalized partial volume joint histogram estimation. *IEEE Transaction on Medical Imaging*, 22(9):1111–1119, 2003.
- [9] j. Pluim. Mutual Information Based Registration of Medical Images. PhD thesis, Image Since Institut, Uthrecht University, Netherlands, 2000.

- [10] F. Maes, A. Collignon, D. Vandermeulen, G. Marchal, and P. Suetens. Multimodality image registration by maximization of mutual information. *IEEE Transactions on Medical Imaging*, 16(2), 1997.
- [11] A. Maintz. A survey of medical image registration. Oxford University Press, 1997.
- [12] C. R. Meyer, J. Boes, B. Kim, and P. Bland. Evaluation of control point selection in automatic mutual information driven 3d warping. in Proc of MICCAI'98, Cambridge, USA., (1496):944–951, 1998.
- [13] T. Mäkelä, P. Clarysse, O. Siplilä, N. Pauna, Q.C Pham, T. Katila, and I. E. Magnin. A review of cardiac image registration methods. *IEEE Transactions on Medical Imaging*, 21(9):1011–1021, 2002.
- [14] J. Pavía, D. Ros, A.M. Catafau, Lomeña, M. Humuet, and j. Setoaiin. Three-diemnsional realignment of activation brain single-photo emission tomographic studies. *European Journal of Nuclear Medicine and Molecular Imaging*, 21:1298–1302, 1994.
- [15] J. P. Pluim, J. B. Maintz, and M. A. Viergever. Mutual information matching and interpolation artefacts. *Image Processing*, 3661, 1999.
- [16] J. P. Pluim, J. B. Maintz, and M. A. Viergever. Mutual information based registration of medical images: a survey. *IEEE Transaction on Medical Imaging*, 22(8):986–1013, 2003.
- [17] J. Rigau, M.Feixas, M.Sbert, A.Bardera, and I.Boada. Medical image segmentation based on mutual information maximization. *IEE transacion in medical images.*
- [18] K. Shields, D.C. Barber, and S. B. Sheriff. Image registration for the investigation of atherosclerotic plaque movement. *Information Processing* in Medical Imaging, 687:438–458, 1993.
- [19] P.J. Slomka, G.A. Hurwitz, J. Stephenson, and T. Cradduck. Automated alignment and sizing of miocardial stress and rest scans to three-dimensional normal templates using an image registration algorithm. *European Journal of Nuclear Medicine and Molecular Imaging*, 36:1115–1122, 1995.
- [20] C. Studholme, D.L Hill, and D.J. Hawkes. Multiresolution voxel similarity measures for mr-pet registration. *Information Processing in Medical Imaging*, pages 287–298, 1995.
- [21] P. Viola and W. Wells. Alignment by maximization of mutual information. In Proceedings of the 5th international conference on computer vision, 1995.

- [22] M. Y. Wang, J.M Fitzpatrick, C.R. Maurer, and R.J. Maciunas. An automatic technique for localizing extrenally attaches markers in mr and ct volume images of the head. *Medical Imaging: Image Processing*, 2167:214–224, 1994.
- [23] Y.T. Zou. Multi-sensor image fusion. IEEE, Conference on Image Processing, 21:1298–1302, 1994.