

## 2. Materiales y Métodos

---

### 2.1. Imágenes

Empleamos [19] imágenes MRI del cerebro de niños de ocho años, obtenidos en un equipo General Electric 3.0 Tesla MR750 (Milwaukee, Wisconsin USA). Imágenes volumétricas fueron obtenidas con la técnica SPGR con frecuencia FoV = 24, fase FoV = 10.75, espesor del corte = 1.3, ángulo inclinación = 12, frecuencia = 320, fase = 320, NEX = 1, and TR = 8.2 TE = full min, con un total de 180 cortes axiales de 1.3 de espesor. Además imágenes funcionales fMRI fueron obtenidas con un paradigma de movimiento de mano y parámetros: FoV = 24.6, frecuencia, fase FoV = 1.00, espesor del corte = 3, TR = 3000, TE = 40, ángulo inclinación = 90, frecuencia = 64, fase = 64 y NEX = 1, con un total de 44 imágenes.

El escáner MRI está en el instituto de Neurobiología de la UNAM. También se emplearon imágenes funcionales provenientes del escáner PET (Phillips) de la Facultad de Medicina de la UNAM de características similares, pero resolución más baja de 64 x 64 x 64.

### 2.2. Software

#### 2.2.1. *MATLAB*

Es un lenguaje de programación en un entorno interactivo desarrollado por Mathworks, para desarrollo de algoritmos, análisis y visualización de datos y cálculo numérico. Es especialmente útil debido a que cuenta con conjuntos de herramientas orientadas a aplicaciones específicas, como el procesamiento de imágenes, denominadas *toolbox*. Además, permite la elaboración de GUIs (*Graphical User Interface*, interfaz gráfica de usuario), con herramientas que facilitan su diseño y construcción [24].

Se utilizó la versión 7.3. (R2006b) de MATLAB para WINDOWS para desarrollar los métodos propuestos de fusión así como para implementarlos dentro de una GUI.

### **2.2.2. SPM**

Para el registro de las imágenes se recurrió al software SPM (*Statistical Parametric Mapping*, Mapeo paramétrico estadístico), cuya versión actual, lanzada en abril de 2009, es SPM8 y fue la que se utilizó.

SPM es un software orientado al análisis estadístico de imágenes cerebrales, desarrollado por *The Wellcome Trust Centre for Neuroimaging del Institute of Neurology de la University College London*; está basado principalmente en funciones de MATLAB y es distribuido como software libre, bajo licencia GNU GPL (*GNU General Public License*, Licencia pública general de GNU) [7].

Dicho software implementa los conceptos teóricos del mapeo paramétrico estadístico, el cual es un conjunto de procedimientos estadísticos utilizados para probar hipótesis de datos provenientes de neuroimágenes funcionales, como identificar efectos específicos, caracterizar la anatomía funcional o detectar cambios relacionados con algún padecimiento. El análisis realizado por SPM a los datos de las neuroimágenes funcionales puede dividirse en: procesamiento espacial, estimación de los parámetros de un modelo estadístico y por último inferencias sobre los parámetros estimados con estadísticas apropiadas [11].

A grandes rasgos, todo el proceso (fig. 2.1) puede describirse como una primera etapa de *procesamiento* cuyo objetivo es reducir los elementos no deseados en las imágenes, provocados principalmente por el movimiento, y proporcionar un mismo marco o referencia anatómica a los datos provenientes de diferentes imágenes de un mismo sujeto, o datos de diferentes sujetos para poder combinarlos posteriormente. Después de ser procesados, los datos se encuentran listos para un segundo *análisis estadístico*, donde son modelados para dividir las respuestas neurofisiológicas observadas en efectos y errores, formar estadísticas mediante sus estimaciones, y finalmente *realizar inferencias* sobre los efectos de interés.

## ANÁLISIS DE DATOS




Fig. 2.1 Esquema general de las transformaciones efectuadas para obtener a partir de una secuencia de imágenes un mapa estadístico paramétrico. Imagen tomada de [11].

De las tres etapas mencionadas, la primera es la única que vamos a utilizar (está indicada en la fig. 2.1), porque es donde se encuentra la opción de registro. SPM realiza el registro mediante un algoritmo que optimiza una función de medición de la similitud de todos los posibles pares de vóxeles; estas medidas de similitud provienen de las llamadas *entropías conjuntas y marginales*, y de minimizar la entropía conjunta y maximizar la información mutua [11]. Estas últimas son de hecho técnicas de fusión, pero con finalidades distintas a las que nos interesa (por ejemplo, se pierde la identidad de las imágenes de entrada). Otros aspectos de SPM se relacionan con técnicas de fusión y en la etapa de los mapas estadísticos paramétricos (fig. 2.1, a la derecha) hay interés de una visualización combinada o simultánea de la inferencia

estadística y la imagen anatómica, pero SPM se limita a superponerlas, ocultando detalles estructurales.

### **2.3. Objetivos de la fusión**

Como se mencionó en el capítulo uno, la fusión de imágenes es utilizada en distintas áreas, por lo que es difícil tener un método único que satisfaga completamente las necesidades de cada aplicación.

Aún con estas particularidades, es posible identificar en la literatura ciertos objetivos principales y muy diferentes de la fusión de imágenes como visualización, mejora y corrección, análisis y reconocimiento de formas, y restauración u obtención de modelos.

#### **2.3.1. Combinar información incompleta de distintas fuentes**

En algunas ocasiones cuando adquirimos una imagen, notamos la presencia de anomalías (datos defectuosos o información faltante). Se puede obtener una imagen de calidad superior si se combinan distintas imágenes de la misma escena [29]. Generalmente se pierde la identidad de las imágenes utilizadas, ya que como resultado se obtiene una imagen que contiene los “mejores” elementos de cada una o se complementan.

Por ejemplo, la transformada de Hermite permite detectar las estructuras relevantes en imágenes, de acuerdo a modelos de la visión humana, y eliminar aquellas que las afectan y así obtener una mejor reconstrucción de estas estructuras [6].

Estas anomalías pueden deberse a la presencia de ruido o zonas borrosas, niveles de exposición no adecuados o que algún objeto de interés se encuentre fuera de foco. Así que a partir de imágenes, que se asume están alineadas, “incompletas” o “parciales” de un objeto o escena, adquiridas bajo diferentes condiciones tales como distintos niveles de exposición (multiexposición), o desde varios puntos de vista (multivista), o distintas distancias focales (multifocales). En estos casos se recurre a métodos de fusión que permitan identificar las “mejores” partes de cada una y formar una imagen final donde converjan estos elementos.

Las imágenes originales no necesariamente tienen que haber sido adquiridas por el mismo instrumento, pueden pertenecer a otro que refleje características similares; por ejemplo se puede fusionar estudios de CT y MRI al fin de aumentar la calidad de la información anatómica presente en ambas modalidades.

Este tipo de fusión también puede extenderse a aplicaciones para lograr superresolución, donde las imágenes de entrada de baja resolución son fusionadas para conseguir una imagen de alta resolución [9]. En este punto es importante distinguir entre el mejoramiento visual de la imagen (superposición), y una interpolación real de datos para obtener una mayor resolución (por ejemplo, mediante *wavelets*) [29].

### **2.3.2. Visualizar, manteniendo la identidad de cada modalidad**

Cuando se cuenta con imágenes de una misma escena, adquiridas con diferentes sensores, resulta complicado manejar la información conjunta que proveen las imágenes. Utilizando métodos adecuados de fusión, se pueden visualizar simultáneamente las distintas propiedades de cada una de las imágenes originales, facilitando la evaluación, y obteniendo resultados y conclusiones a los que difícilmente se llegaría revisando las imágenes por separado. Generalmente en la imagen fusionada se preserva la identidad de las imágenes o fuentes originales.

Los tratamientos médicos que incluyen la toma de varios estudios multimodales resultan beneficiados con este tipo de fusión ya que proporciona información anatómica y fisiológica complementaria de la misma parte del cuerpo, incrementa la confianza en los datos al utilizar la llamada *información mutua*, además de proveer un marco de referencia anatómico a la imagen funcional; lo que permite acceder a información no visible para el especialista, cuando las imágenes son estudiadas individualmente [31]. Adicionalmente ayuda a compensar las limitaciones propias de las modalidades involucradas (baja resolución, falta de información metabólica).

Por otra parte, favorece a la caracterización y se tiene mayor precisión para localizar y delimitar lesiones o anomalías (p. ej., un tumor), lo que se traduce en un diagnóstico superior, siendo el paciente el mayor beneficiado por un tratamiento más adecuado a sus necesidades y

en el caso de una radioterapia, utilizar técnicas de mayor precisión que causen daños mínimos al tejido sano.

Igualmente sirve para detectar y evaluar cambios en imágenes de un objeto o escena (ya sean de una misma o diferente modalidad, e incluso otro tipo de datos) adquiridas en diferentes tiempos. La fusión de éstas imágenes permite recopilar en una sola imagen los cambios sufridos en un determinado tiempo.

Permite el monitoreo de cambios de tamaño o forma de estructuras en un periodo de tiempo, el cual puede abarcar años (estudios neurológicos de una atrofia cerebral) o segundos (imágenes de perfusión) [16]. Como puede verse, tanto para este tipo de aplicaciones como para las anteriormente mencionadas, es importante que las imágenes se encuentren registradas, para no obtener conclusiones equivocadas.

Se debe hacer especial hincapié en cuanto a los métodos adecuados de fusión debido a que se busca combinar de la mejor forma posible en una sola imagen, tanto las características mutuas como las contrastantes (complementarias) que nos proporciona cada tipo de imagen de una escena.

Aunque visualizar manteniendo la identidad de cada imagen sea justamente el objetivo a desarrollar en esta tesis, es conveniente conocer los restantes, porque aunque todos compartan términos, características y métodos, no implica que puedan aplicarse de forma generalizada, es importante considerar las particularidades.

### ***2.3.3. Comparar imágenes, o evaluar un método de procesamiento***

Después de que dos o más imágenes han pasado por un proceso, generalmente un registro geométrico o alineación, es necesario comprobar que éste fue realizado correctamente. Una forma de hacerlo es fusionar las imágenes registradas y mediante la evaluación visual (de un experto) [31], verificar el resultado. Una simple substracción puede revelar la tendencia o error en la alineación, por ejemplo al aparecer bordes orientados, en el caso de una traslación incorrecta.

A pesar de contar con métodos que ofrecen una mayor precisión usando datos simulados, modelos o marcadores de referencia (o “fiduciaros”), existen imágenes con las que no se cuenta con una “imagen estándar” para realizar la comprobación, como con las imágenes médicas, donde no se tienen modelos específicos para cada paciente. En estas circunstancias, la fusión de imágenes permite realizar una evaluación aceptable [2].

Es de notar que la comparación puede ser cuantitativa, al obtener una cifra que califique el grado de comparación o diferencia (inclusive error, p. ej., durante una alineación de imágenes de objetos diferentes), pero también puramente cualitativa, mediante la visualización de dichas diferencias, usando escalas de color o métodos de fusión como los presentados en esta tesis, de acuerdo al objetivo 2.3.2. Una barra vertical u horizontal de dicha escala, incluiría el valor numérico correspondiente a cada variación de color, pero también este se podría indicar al posicionar el cursor en la región coloreada.

#### **2.3.4. Combinación general de métodos, modelos, algoritmos.**

Un conjunto de imágenes de la misma escena tomadas con el mismo sensor pero diferentes puntos de vista sirven para crear una reconstrucción tridimensional de la escena [9]. Esta fusión es ocupada en métodos de estereoscopia, en tomografías o incluso para realizar una representación tridimensional empírica con las imágenes no controladas adecuadamente cuando fueron adquiridas [3]. Incluso se puede determinar la efectividad de métodos, por ejemplo comparar el criterio de máxima información mutua y optimización por mínimos cuadrados.

Cuando datos e imágenes de múltiples fuentes son introducidas al procesamiento, la precisión en la validación de presencia o ausencia de objetos de interés en una escena se ve beneficiada, al igual que su categorización y clasificación [3]. Este enfoque es utilizado frecuentemente en detección remota, ya que permite aprovechar la información proveniente de múltiples dispositivos encargados del estudio de un objeto concreto o área.

Un caso especial en esta categoría sería como auxiliar en la segmentación de imágenes. Si bien es cierto que implica una clasificación, la segmentación tiene como fin primordial extraer determinados objetos tan precisamente como sea posible. Esta ayuda puede consistir

simplemente en utilizar la información complementaria en la identificación de los límites de componente homogéneos de la imagen.

Puede observarse que lograr una clasificación íntegra de los distintos métodos, pretendiendo abarcar todos los matices de la fusión de imágenes, resulta complicado debido principalmente a su creciente uso en el procesamiento de información de diferentes áreas (esta es la razón de muchos términos anteriormente entrecomillados, ya que su significado está ligado a las características propias de los datos involucrados). De ahí la importancia de tener siempre presente con qué clase de información se está trabajando y qué objetivos se quieren alcanzar, ya que, como resultado de esta heterogeneidad, es imposible diseñar un método universal de fusión de imágenes aplicable en todas las situaciones.

#### **2.4. Métodos: operadores de fusión para visualización**

Como vimos en la sección anterior, el tema de esta tesis pertenece al apartado de “fusión para visualización”, ahora es momento de abordar técnicas que permitan realizarlo. En la literatura referente al tema se describen distintos métodos de fusión que permiten visualizar la información contenida en dos imágenes de una forma útil y significativa. En [15] se muestra una variedad de ellos y éstos pueden implicar visualización contigua (es decir una imagen al lado de la otra), técnicas relacionadas con color, selección de elementos de interés en la imagen, operaciones aritméticas o combinaciones de éstas y otras, que involucran por ejemplo los contornos de la imagen de una modalidad y las bajas frecuencias de la imagen de otra modalidad.

Los procedimientos de visualización contigua (tabla 2.1) son de los más sencillos, ya que no hay una combinación de las imágenes involucradas como tal, sino que son desplegadas en pantalla de tal forma que se pueda comparar el contenido [33].




**Tabla 2.1. Visualización contigua**


---

Cursor sincronizado ( <i>linked cursor</i> ):	Las imágenes son mostradas lado a lado, con un par de cursores sincronizados (fig. 2.2a) de tal forma que indiquen puntos correspondientes en ambas imágenes [18]. Esta técnica es útil para explorar características ya muy localizadas, pero no lo resulta tanto para una comparación global. Las imágenes no pierden información y las características presentes en la misma localización en ambas imágenes no interfieren
Vista dividida (cortinilla móvil):	Se coloca una imagen sobre otra en la misma posición y sin mezclarse (fig. 2.2b). Mediante el desplazamiento de una línea divisoria móvil se visualiza la imagen situada debajo, y del otro lado de la división la imagen superior [18].
Visualización dinámica alternada ( <i>blinking</i> ):	Compara dos imágenes mostrándolas sucesiva y cíclicamente, ya sea automáticamente o por medio de un control, en la pantalla. Sirve para encontrar pequeñas y sutiles diferencias entre las imágenes [15].
Ajedrezado (píxeles alternados):	Los datos de dos imágenes aparecen yuxtapuestos en un patrón entrelazado regular (simulando un tablero de ajedrez) (fig. 2.2c). Estos bloques pueden ser del tamaño de un píxel o grupos de NxN píxeles [33].


---



(a)



(b)



(c)

Fig. 2.2. Visualización continua, (a) cursor sincronizado, (b) cortinilla móvil; imágenes tomadas de [18], (c) ajedrezado; imagen tomada de [23].

Estas formas de visualización aunque útiles no son de nuestro completo interés, ya que estamos más interesados en métodos que engloben en una sola imagen los datos de ambas modalidades simultáneamente.

### 2.4.1. Alpha blending

Un método utilizado frecuentemente para visualizar simultáneamente imágenes de diferentes modalidades, principalmente dentro del software comercial, es el conocido como *alpha blending* [34], el cual promedia ponderadamente píxel por píxel las imágenes mediante un factor de transparencia alfa ( $\alpha$ )

$$I_{\alpha b} = (1 - \alpha) I_A + \alpha I_F \quad (2.1)$$

donde

$I_{\alpha b}$  - Imagen fusionada

$I_A$  - Imagen de una modalidad anatómica

$I_F$  - Imagen de una modalidad funcional

$\alpha \in [0, 1]$ .

Si  $\alpha$  es un valor ajustable, la relación entre las imágenes cambiaría continuamente y  $I_{\alpha b}$  aparecería como  $I_A$  con una contribución mayor o menor de la  $I_F$ , mientras que para los valores límite  $\alpha = 0$  y  $\alpha = 1$  sería visible únicamente  $I_A$  o  $I_F$  respectivamente.

Para poder distinguir ambas modalidades en el resultado final, se muestran en colores diferentes (p.ej.  $I_A$  en magenta e  $I_F$  en verde)

$$I_{\alpha b_{RGB}} = ((1 - \alpha) I_A, \alpha I_F, (1 - \alpha) I_A) \quad (2.2)$$

O bien,  $I_A$  se mantiene en niveles de gris e  $I_F$  en color (p. ej. verde)

$$I_{\alpha b_{RGB}} = ((1 - \alpha) I_A, (1 - \alpha) I_A + \alpha I_F, (1 - \alpha) I_A) \quad (2.3)$$

tanto (2.2) como (2.3) tienen un atributo vectorial de tres canales y están expresadas en el espacio de color RGB (ver A.2.1).

A pesar de su uso tan común en la práctica médica como en la investigación, se decidió implementar la técnica de *alpha blending* principalmente como referencia, para que los especialistas a partir de su experiencia en el uso de esta técnica les sirva para evaluar los métodos propuestos en este trabajo.

### **2.4.2. Traslape mínimo**

Como se ha mencionado anteriormente, cada modalidad de imagen enfatiza propiedades diferentes del cerebro: una estructuras y la otra actividad metabólica. Tomando este criterio como referencia se busca desarrollar un método que resalte aún más estas características con distintos filtros y operadores que minimicen el traslape de información entre las imágenes, separando visualmente cada modalidad.

Las imágenes funcionales presentan contornos poco definidos, y esta característica se acentúa al aplicar filtros de suavizado, como un filtro gaussiano (ver sección 2.4.2.6), que atenúa y resalta las regiones de actividad, despejando los bordes.

Por el contrario, en las modalidades anatómicas la información que nos interesa conservar son justamente los bordes de estas estructuras. Utilizando operadores de detección de bordes se podrán preservar y así servir de guía a la información funcional en la imagen fusionada ( $I_{TM}$ ).

#### **2.4.2.1. Detección de bordes**

El proceso de detección de bordes permite simplificar el análisis de imágenes reduciendo drásticamente la cantidad de datos a manejar, a la vez que preserva la información estructural de los límites de un objeto. Además, el análisis de forma requiere a menudo de una representación del objeto mediante contornos.

Los bordes son líneas que sirven para demarcar dos regiones diferentes y alrededor de los cuales la imagen presenta variaciones bruscas en los niveles de gris [1]. En un órgano como

el cerebro tales regiones tienen características funcionales distintas, por lo que la demarcación debe ser precisa. Los bordes generalmente son modelados como una rampa en lugar de un cambio abrupto de intensidad debido a posibles imperfecciones durante la adquisición de la imagen (fig. 2.3) [12]. Estos puntos de alto contraste pueden ser detectados calculando las diferencias de intensidad.




Fig. 2.3. Modelo de un borde digital (a) ideal, (b) real. Imagen tomada de [12].

Así la primera derivada será cero en todas las regiones de intensidad constante, y tendrá un valor constante en toda la transición de intensidad. Por otro lado la segunda derivada es cero en todos los puntos, excepto en el comienzo y final de una transición de intensidad (fig. 2.4). Por lo tanto una variación de intensidad se manifiesta como un cambio brusco en la primera derivada, y presenta un paso por cero<sup>1</sup> (cambia de signo su valor) en la segunda derivada [27].

---

<sup>1</sup> Zero-crossing.




Fig. 2.4. Primera y segunda derivada de un perfil de nivel de gris. Imagen tomada de [12].

La detección de bordes es esencialmente una operación para localizar cambios locales significativos de los niveles de intensidad de una imagen. El cambio de intensidad es medido por el gradiente de la imagen [1].

#### 2.4.2.2. Gradiente

El gradiente de una imagen [12]  $f(x,y)$  en un punto  $(x,y)$  se define como un vector bidimensional perpendicular al borde dado por (2.4), donde el vector gradiente apunta en la dirección de variación máxima de  $f$  en el punto  $(x,y)$ .

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix}. \quad (2.4)$$

Con magnitud y dirección dadas por

$$G = |\nabla f| = \sqrt{G_x^2 + G_y^2}, \quad (2.5)$$

$$\phi(x, y) = \tan^{-1} \frac{G_y}{G_x}. \quad (2.6)$$

La magnitud del gradiente también puede obtenerse con los valores absolutos<sup>2</sup>

$$G \approx |G_x| + |G_y|. \quad (2.7)$$

La relación para determinar si un punto es o no borde [27] es

$$g(x, y) = \begin{cases} 1 & \text{si } G > T \\ 0 & \text{si } G \leq T \end{cases} \quad (2.8)$$

donde

$T$  es un valor de umbral no negativo.

Los operadores gradiente calculan el cambio en las intensidades de los niveles de gris y también la dirección en el que cambio ocurre. Esto es calculado por la diferencia de valores de los píxeles vecinos (las derivadas a lo largo de el eje X y eje Y). En una imagen bidimensional los gradientes se aproximan a [1]:

---

<sup>2</sup> Puede utilizarse está expresión porque el valor de  $G$  no es tan importante como la relación entre diferentes valores. Se va a decidir si un punto es un borde según si la magnitud supere o no un determinado umbral [27]. Computacionalmente esta forma es más utilizada.

$$G_x = f(x+1,y) - f(x,y) \tag{2.9}$$

$$G_y = f(x,y+1) - f(x,y).$$

Los filtros de estas ecuaciones pueden ser implementados utilizando máscaras de convolución.

### 2.4.2.3. Detectores de bordes

El objetivo de los detectores consiste en que dada una imagen, que puede o no contener ruido, localizar los bordes más probables generados por los elementos de la escena y no por el ruido. Los operadores para la extracción de bordes (tabla 2.2), se distinguen principalmente entre los basados en la primera o segunda derivada.

**Tabla 2.2. Detectores de bordes**

1ª derivada	Canny	2ª derivada	Cruce por cero
	Kirsch		Diferencia de gaussianas
	Prewitt		Laplaciano
	Roberts		Laplaciano del gaussiano
	Sobel		

### 2.4.2.4. Operadores 1ª derivada

Operador Roberts:

El operador Roberts [1, 12, 27] es un operador gradiente de 2x2, marca solamente los puntos de borde de una imagen (fig. 2.5a) sin informar sobre la orientación de estos. Provee la aproximación más simple de la primera derivada

$$G_x = z_5 - z_9 \tag{2.10}$$

$$G_y = z_6 - z_8.$$

De acuerdo a (2.7) la magnitud del gradiente es

$$G = (z_5 - z_9) + (z_6 - z_8). \tag{2.11}$$



Estos operadores son implementados con las máscaras mostradas en fig. 2.5b.

Operador Sobel:

También pueden utilizarse máscaras de filtrado de tamaño 3x3 [1, 12, 27] (fig. 2.5c), cuya aproximación es

$$G_x = (z_1 + 2z_2 + z_3) - (z_7 + 2z_8 + z_9) \quad (2.12)$$

$$G_y = (z_1 + 2z_4 + z_7) - (z_3 + 2z_6 + z_9).$$

El objetivo de utilizar un valor de peso 2 es lograr un mayor suavizado, dándole mayor importancia al punto central.

Operador Prewitt:

El operador Prewitt [12, 27] es similar al de Sobel, sólo diferenciándose en los coeficientes (fig. 2.5d).

$$G_x = (z_1 + z_2 + z_3) - (z_7 + z_8 + z_9) \quad (2.13)$$

$$G_y = (z_1 + z_4 + z_7) - (z_3 + z_6 + z_9).$$




Fig. 2.5. (a) Región de una imagen. Máscaras para: (b) operador Roberts; (c) operador Sobel; (d) operador Prewitt.

Detector de Canny:

El algoritmo de Canny [1, 27] se fundamenta en la teoría de los operadores de primera derivada, sólo que con este método se pueden extraer bordes y cerrar contornos evitando posibles rupturas de los mismos durante su extracción. El proceso puede desglosarse en tres módulos principales:

**Tabla 2.3. Algoritmo Canny**

---

1) Obtención del gradiente (magnitud y ángulo en cada píxel).
2) Adelgazamiento del ancho de los bordes, obtenidos del gradiente, hasta lograr bordes de píxel de ancho conocido. Dicho adelgazamiento se denomina supresión de valores no-máximos locales.
3) Histéresis de umbral al resultado de la supresión de valores no-máximos, para eliminar máximos locales creados por el ruido.

---

Este detector presenta una buena inmunidad al ruido y al mismo tiempo detecta bordes con errores mínimos, debido a que la imagen primero es convolucionada con un filtro gaussiano ( $G_\sigma$ ) con desviación estándar ( $\sigma$ ). Posteriormente se obtiene el gradiente de la imagen suavizada resultante.

#### 2.4.2.5. Operadores con la 2ª derivada

El principio de la detección de bordes utilizando segundas derivadas es detectar únicamente aquellos puntos que posean máximos locales en los valores del gradiente como puntos de borde. En este caso, se tiene un pico en la primera derivada y un cruce por cero en la segunda en los puntos de borde. Por lo tanto los puntos en los cuales la segunda derivada tiene un cruce por cero son tratados como puntos de borde [1].

Este enfoque consiste básicamente en definir una formulación discreta de la derivada de segundo orden, para construir una máscara de filtrado basada en esta formulación [12].

Laplaciano:

El laplaciano [12, 27] de una función  $f(x,y)$  está definido como

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}. \quad (2.14)$$

Como en el caso del gradiente, el laplaciano puede implementarse en forma discreta:

$$\begin{aligned} \nabla^2 f &= [f(x+1, y) + f(x-1, y) - 2f(x, y)] + [f(x, y+1) + f(x, y-1) - 2f(x, y)] \\ &= [f(x+1, y) + f(x-1, y) + f(x, y+1) + f(x, y-1)] - 4f(x, y). \end{aligned} \quad (2.15)$$

Esta ecuación puede ser implementada en todos los puntos  $(x, y)$  de una imagen convolucionando la imagen utilizando la máscara mostrada en figura 2.6a. Una definición alterna de la segunda derivada digital toma en consideración los elementos diagonales y puede ser implementada con la máscara de la figura 2.6b.

$$\begin{array}{ccc} \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} & & \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix} \\ \text{(a)} & & \text{(b)} \end{array}$$

Fig. 2.6. Máscaras de filtrado usadas para implementar el laplaciano digital.

Las máscaras laplacianas representan aproximaciones del operador laplaciano, éstas son simétricas rotacionalmente, por lo que son capaces de detectar bordes en todas las direcciones espaciales. El problema principal con el operador laplaciano es que es excesivamente sensible al ruido, por lo que no es utilizado en su forma original.

#### Laplaciano de la gaussiana (LoG):

El operador laplaciano es susceptible al ruido; para reducirlo se utiliza el operador LoG (*Laplacian of the Gaussian*, Laplaciano de la gaussiana) (ver 2.16), el cual primero efectúa un desvanecimiento gaussiano para después obtener su laplaciano, lo cual es equivalente a convolucionar la imagen con el laplaciano de una gaussiana (ver 2.17).

$$\nabla^2 \mathbf{G}(\mathbf{x}, \mathbf{y}) = \frac{1}{\pi \sigma^4} \left[ 1 - \frac{\mathbf{x}^2 + \mathbf{y}^2}{2\sigma^2} \right] e^{-\frac{\mathbf{x}^2 + \mathbf{y}^2}{2\sigma^2}}, \quad (2.16)$$

$$\nabla^2 (\mathbf{G}_\sigma * I) = (\nabla^2 \mathbf{G}_\sigma) * I. \quad (2.17)$$

Este operador es menos sensible al ruido porque la función gaussiana reduce el ruido presente en la imagen y por lo tanto se minimiza la probabilidad de detectar bordes falsos al aplicar el laplaciano.

Es importante notar que los diferentes operadores para obtener y realzar bordes ofrecen distintas ventajas y desventajas, sobretodo respecto a cómo tratar el problema del ruido en bordes apenas detectables. Por ello es difícil su comparación, pues un filtro puede funcionar muy bien con unas imágenes, pero no con otras. Por fortuna, en nuestro caso no requerimos de una extracción completa, ni precisa de los contornos, pues el objetivo es de visualización, no de segmentación.

#### 2.4.2.6. Filtro gaussiano

Es un operador de convolución utilizado para “suavizar” una imagen, que remueve detalle y ruido. En una dimensión la función gaussiana tienen la siguiente forma

$$\mathbf{G}_\sigma(\mathbf{x}) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{\mathbf{x}^2}{2\sigma^2}} \quad (2.18)$$

donde

$\sigma$  es la desviación estándar.

Su gráfica se muestra en la figura 2.7.




Fig. 2.7. Función gaussiana 1-D con diferentes valores de  $\sigma$ .

Podemos ver que el valor de  $\sigma$  controla el ancho de la gráfica de la función gaussiana.

La forma de un filtro gaussiano pasa-bajas de dos dimensiones está dada por:

$$G_{\sigma}(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.19)$$

Cuya gráfica se muestra en la figura 2.8.




Fig. 2.8. Filtro gaussiano 2-D.

### **2.4.3. Fusión en espacios de color**

El uso del color mejora la interpretación de la información contenida en una imagen, ya que simplifica su análisis y brinda la posibilidad de incrementar la cantidad de datos presentes; el carácter vectorial del atributo en color justamente permite visualizar información que es independiente, pues se pueden usar varias combinaciones de canales.

En fusión de imágenes una de las formas más sencillas es presentar una modalidad en color y la otra en escala de grises [33]. Acercamientos más sofisticados involucran el uso de distintos espacios de color y transformaciones entre ellos, que codifican la información presente en alguno de sus elementos [15].

La idea básica en este tipo de fusión es emplear algún modelo de color de la familia HSI (*Hue, Saturation and Intensity*, ver anexo A.2.2) para codificar en sus canales los datos anatómicos y funcionales, con la finalidad de usar el color como forma de preservar y distinguir un tipo de información de otra. En adelante, consideraremos imágenes de atributo vectorial con tres componentes, dependiendo del espacio de color ( $r, g, b$  para el espacio RGB;  $h, s, v$  para el espacio HSV, etc.).

A diferencia de este tipo de fusión, muchos equipos de imagenología médica realizan una “fusión” donde simplemente se superpone la información funcional (usualmente manchas pequeñas en color), ocultando los detalles anatómicos. Dicha superposición resulta útil en el estudio de activaciones puntuales, como en el caso de la corteza sensoriomotora, aunque en tareas muy básicas (por ejemplo, el movimiento de un sólo dedo).

En cambio, el enfoque de fusión en espacios de color que adoptamos, permite concentrar, como intensidades, las variaciones de niveles de gris, o en general, los niveles de intensidad de los detalles finos característicos de las modalidades anatómicas. Mientras tanto, el color es usado para representar, como modulación tonal, las variaciones “lentas” de información (o bajas frecuencias), propias de las modalidades funcionales [22], que en todo caso, presentan bordes muy difusos, o ninguno.

Como primer paso es necesario asignarle colores a  $I_F$ , posteriormente pasarla a un espacio de la familia HSI e introducir la información de la imagen  $I_A$ , y finalmente regresar al espacio RGB para poder visualizar el resultado de dicha fusión.

Para la primera parte se utilizará un mapa o paleta de color<sup>3</sup> que puede ser de los incluidos en el software MATLAB o uno diseñado ex profeso. Se busca que este mapa de color no sólo ayude a distinguir las regiones de actividad, también que sea útil para visualizar los cambios provocados por la fusión. Una vez con  $I_F$  en RGB ( $I_{F_{RGB}}$ ) es posible trasladarla a otro espacio de color.

La diferencia más notable entre los espacios HSV y HSL radica en que la saturación máxima de un matiz se encuentra cuando  $V=1$  o  $L=0.5$  respectivamente, esto debido a su representación geométrica (ver detalles en el Anexo A). Tomando en cuenta que es precisamente este canal donde se piensa efectuar la fusión, es necesario que el espacio de color que utilicemos proporcione flexibilidad respecto a los cambios que provocará la fusión.

Aunque en el caso de HSV cualquier valor de  $V$  menor a uno tenderá a oscurecer la imagen, en HSL los valores de  $L$  mayores a 0.5 aclararán la imagen pero con el riesgo de pérdida importante de información ya que entre más cercano se encuentren al uno se empezará a blanquear la imagen.

Por eso se decidió utilizar el espacio de color HSV, además de ser de los más ocupados en la bibliografía debido a lo complicado que pueden resultar las operaciones de transformación

---

<sup>3</sup> Un mapa de color o *colormap* es una matriz de  $m \times 3$ , cuya longitud  $m$  es igual al número de colores que define. Cada columna del mapa especifica los componentes rojo, verde y azul de un solo color.

del espacio HSL por el doble cuerpo geométrico, y por la facilidad adicional que brinda al ya estar la función de conversión programada en MATLAB.

#### 2.4.3.1. Operaciones de fusión

Una vez con la imagen vectorial  $I_F$  en el espacio HSV,

$$I_{F_{HSV}} = (H, S, V) \quad (2.20)$$

Donde, usando la notación de MATLAB para arreglos y matrices, tenemos las siguientes imágenes escalares

$$H = I_{F_{HSV}}(:, :, 1)$$

$$S = I_{F_{HSV}}(:, :, 2)$$

$$V = I_{F_{HSV}}(:, :, 3)$$

se utilizará el canal de valor  $V$  para introducir la información anatómica, ya que se tratará que la información funcional quede exclusivamente descrita por el color en los canales  $H$  y  $S$ . Se probarán distintas operaciones en el canal  $V$ , buscando observar en una sola imagen ( $I_{EC}$ , donde  $EC$  indica el espacio de color en el cual se realizó la fusión: RGB, HSV, HSI, etc.) tanto la información funcional dada por el color, así como de la anatómica. Dentro de las operaciones a estudiar están:

$$I_{HSV} = (H, S, I_A) \quad (2.21)$$

$$I_{HSV} = (H, S, I_A + I_F) \quad (2.22)$$

$$I_{HSV} = (H, S, \frac{I_A + I_F}{2}) \quad (2.23)$$

$$I_{HSV} = (H, S, I_A + \frac{I_F}{n}) \quad (2.24)$$

Es importante notar que aunque la fusión se lleve a cabo en el espacio de color HSV, la imagen final es trasladada al espacio RGB para poder visualizarla correctamente.

Se estudiará cómo afectan a la información funcional y que tan efectivas son estas operaciones para lograr nuestros objetivos de fusión para visualización.



## 2.5. Interfaz gráfica

Con el propósito de facilitar la evaluación de los métodos propuestos se diseñó una interfaz gráfica de usuario (GUI). Se utilizaron las herramientas que proporciona MATLAB, como su propio ambiente de creación de GUIs, llamado GUIDE, así como funciones incluidas en el *toolbox* de procesamiento de imágenes.

Una GUI es una representación gráfica, en una o más ventanas, que contiene controles llamados componentes (p. ej., menús, barra de herramientas, barra de desplazamientos, casilla de verificación, etc), que permiten al usuario realizar tareas interactivas, sin necesidad de que éste conozca a detalle cómo se llevan a cabo. Cada componente de la GUI, está asociado con una o más rutinas conocidas como *callbacks*. Su ejecución es activada por una acción particular del usuario, como un clic del ratón, presionar un botón (*push button*) o seleccionar algún elemento de un menú. Este tipo de programación se conoce como programación orientada a eventos, la ejecución de los *callbacks* es controlada por eventos externos al software [17].

### 2.5.1. Diseño GUI

Si bien es cierto que los métodos propuestos pueden implementarse como funciones o programas de MATLAB, utilizar una GUI facilita revisar cada uno de ellos, evitando tener que regresar a los archivos para modificar su estructura, cada vez que haya algún cambio en los parámetros. Además, previendo pruebas futuras, favorece el manejo en usuarios que sólo tengan que evaluar la funcionalidad de los métodos. Pensando principalmente en este último tipo de usuario, y que se requiere básicamente un software de visualización, la GUI a implementar deber ser sencilla, práctica en cuánto a sus controles y perceptualmente clara.

La GUI diseñada consta de un menú principal (fig. 2.9) y de otras tres ventanas para cada tipo de fusión. En el menú principal se seleccionan los archivos de las imágenes o volúmenes a fusionar, si estos coinciden en cuánto a sus dimensiones, se activan tres *push buttons* que permiten elegir algún método de fusión; además se obtienen los datos que se utilizarán en cualquiera de los métodos seleccionados.

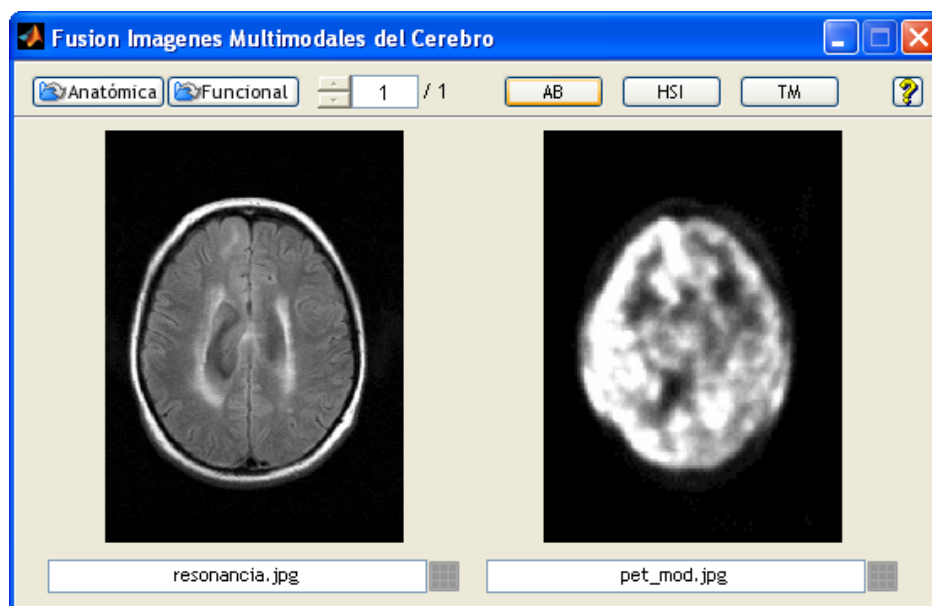


Fig. 2.9. Menú principal.

Las ventanas para cada tipo de fusión cuentan con una estructura similar. En la parte central se despliegan tres imágenes, la de mayor tamaño es la imagen fusionada, mientras que a su costado izquierdo se muestra cada modalidad sin fusionar. En la parte superior se ubica una barra de herramientas, en donde se pueden cambiar las imágenes fusionadas, si se está trabajando con un conjunto de ellas; también están los botones que activan las herramientas de zoom, mover la imagen, así como regresar al cursor estándar. Adicionalmente se incluyó un botón para guardar la imagen fusionada en la ruta que el usuario indique. En la parte inferior se encuentran los controles correspondientes a cada fusión (tabla 2.4).

**Tabla 2.4. Descripción de los controles principales de cada método de fusión**

Método	Controles
<i>Alpha blending</i>	En este caso, los controles principales (un slider y un campo editor de texto) permiten variar el valor de alfa, entre los valores permitidos [0,1]. También se puede cambiar los colores que se usan para distinguir cada modalidad, ya sea gris y color, o color y color I(fig. 2.10).
Espacio de color	Mediante un menú desplegable se muestran las distintas operaciones de fusión, que se tienen programadas, en los canales del espacio HSV. Además de contar con controles para modificar la intensidad o saturación, de acuerdo a la operación elegida. Así mismo se tiene la

opción de cambiar el mapa de color utilizado, y seleccionar un rango de los niveles de intensidad a mostrar (y fusionar) de la imagen funcional (fig. 2.11).

Traslape mínimo Se puede elegir entre distintos tipos de detectores de bordes, así como modificar sus valores de umbral o sigma de acuerdo al tipo de operador. En cuanto a la imagen funcional, se puede modificar el sigma del filtro gaussiano ocupado para suavizar la imagen (fig. 2.12).




Fig. 2.10. Ventana fusión *alpha blending*.

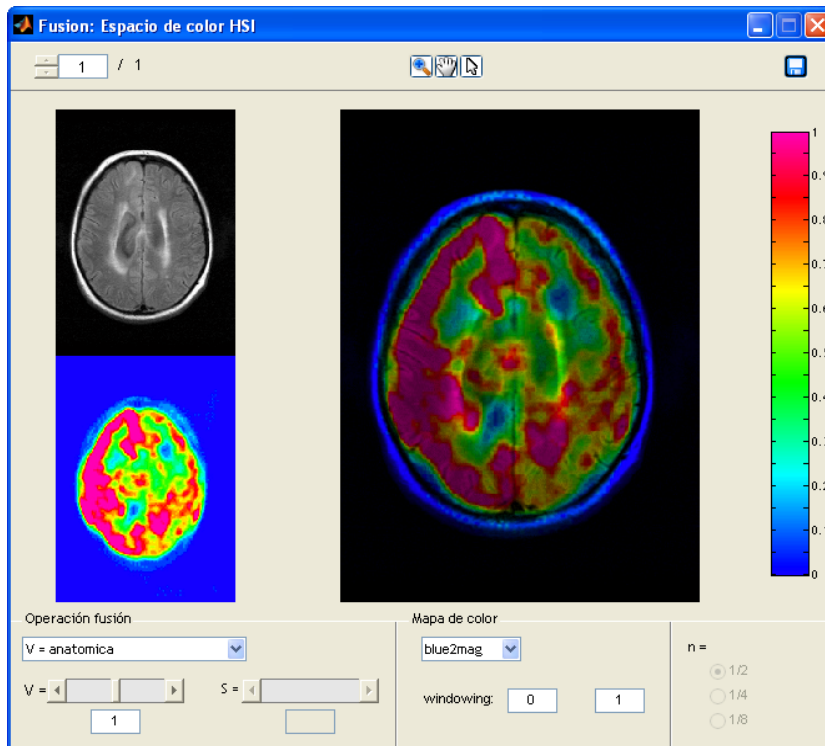


Fig. 2.11. Ventana fusión espacios de color.




Fig. 2.13. Ventana fusión traslape mínimo.