

RECONOCIMIENTO DE TEJIDOS EN IMÁGENES DE RESONANCIA MAGNÉTICA DE CEREBRO A TRAVÉS DE VALORES DE VERDAD DE PREDICADOS DIFUSOS

Gustavo J. Meschino^{a,c}, Rafael A. Espin Andrade^b y Virginia L. Ballarin^c

^aLaboratorio de Bioingeniería, Universidad Nacional de Mar del Plata,
Juan B. Justo 4302, 7600 Mar del Plata, Argentina, gmeschin@fi.mdp.edu.ar

^bFacultad de Ingeniería Industrial, ISPJAE (Universidad Técnica de La Habana),
Calle 114, No. 11901 entre 119 y 129. Cujae. Marianao. Ciudad de La Habana. Cuba.

^cLaboratorio de Procesos y Medición de Señales, Universidad Nacional de Mar del Plata,
Juan B. Justo 4302, 7600 Mar del Plata, Argentina, vballari@fi.mdp.edu.ar.

Palabras Clave: lógica difusa, procesamiento de imágenes, resonancia magnética, tejidos.

Resumen. La principal ventaja de las imágenes de Resonancia Magnética (RM) es su capacidad para reconocer en ellas diferentes tipos de tejidos. Esto permite posteriores cuantificaciones para asistir en el diagnóstico de diferentes patologías. En este trabajo se utiliza Lógica Difusa para evaluar el grado de verdad de predicados que definen los distintos tejidos en base a las intensidades de gris que presentan las imágenes de RM pesadas en T_1 , T_2 y PD. Estos predicados son de la forma “El tejido X es u_1 en T_1 , u_2 en T_2 , u_3 en PD”, siendo u_1 , u_2 y u_3 conjuntos difusos definidos en el rango de gris. Los predicados se elaboran inicialmente en conjunto con médicos especialistas en imágenes, por lo que intentan implementar las consideraciones que ellos mismos aplican al identificar los tejidos que los píxeles de las imágenes representan. El objetivo es determinar qué tejido corresponde a cada píxel, abordando el problema como un sistema de soporte a las decisiones. El procesamiento de la imagen se realiza píxel a píxel. Se utilizan operadores para el cálculo de los conectivos “or”, “and” y la doble implicación basados en el paradigma recientemente desarrollado de la Lógica Compensatoria. El método ha sido exitosamente probado tanto con imágenes simuladas como con imágenes reales de cerebro para determinar líquido cefalorraquídeo, materia gris y materia blanca. Las operaciones involucradas son sencillas, por lo que el tiempo de procesamiento es corto, lo que lo hace adecuado y eficiente para trabajar en estudios 3D, donde debe procesarse una gran cantidad de imágenes.

1 INTRODUCCIÓN

La principal ventaja de las imágenes de Resonancia Magnética (RM) es la discriminación de diferentes tipos de sustancias para una posterior cuantificación de las mismas y de esta manera asistir en el diagnóstico de diferentes patologías. La segmentación de este tipo de imágenes es un requerimiento constante en Medicina. Continuamente se proponen nuevas técnicas para lograr objetivos similares, cada una de ellas con sus ventajas y limitaciones. En general podría afirmarse que los diferentes métodos tienen en común el reconocimiento de diferentes sustancias presentes en el cuerpo mediante la interpretación de las imágenes que el equipo resonador entrega. Algunos métodos se basan en reconocimiento de patrones (Abrás et al. 2001; Bezdek et al. 1993; Coscoso et al. 2003), tomando intensidades de gris o agregando información espacial como en el enfoque del análisis de las texturas presentes. Otros métodos se basan en procesos de diferentes dificultades, como simples umbralamientos, modelos deformables (Zeng et al. 1999), métodos estadísticos (Marroquin et al. 2002), crecimiento de regiones y combinaciones de todos ellos (Germond et al. 2000). Se han aplicado también métodos que provienen de otras disciplinas, como el descubrimiento del conocimiento, para objetivos más específicos, como es la discriminación de diferentes tipos de patologías (Siromoney et al. 2000). Otros paradigmas aprovechan la capacidad de discriminación de las Redes Neuronales con el fin de la clasificación de los píxeles según sus características (Shen et al. 2005; Di Bona et al. 2003) y la potencia de los sistemas basados en agentes para segmentaciones automáticas (Richard et al. 2004).

Una de las dificultades que se presenta en las imágenes de Resonancia Magnética es que hay un gran solapamiento entre las intensidades de gris que presentan diferentes sustancias. Es por eso que un enfoque con técnicas que trabajen con la modelización de la vaguedad parecen ser adecuadas, como es el caso de la que se propone en este trabajo. En este sentido, la Lógica Difusa ofrece un esquema de trabajo adecuado y ha sido empleada en este contexto (Denkowski et al. 2004), conjugando la ventaja de implementar conceptos inciertos con la posibilidad de manejar sentencias en lenguaje natural. La modelación de la vaguedad se logra a través de variables lingüísticas, lo que permite aprovechar el conocimiento de los expertos, al contrario de lo que ocurre en otros métodos más cercanos a las cajas negras y exclusivamente basados en datos, como son, por ejemplo, las redes neuronales. Se puede lograr un sistema que puede ser más fácilmente comprendido y aceptado por los profesionales que no dominan las ciencias matemáticas, como es el caso de los médicos, quienes finalmente serán los usuarios.

En este trabajo se utiliza la Lógica Difusa para implementar las consideraciones que, implícitamente o no, utilizan los expertos cuando interpretan las imágenes multispectrales de Resonancia Magnética.

Se aborda el problema como uno correspondiente a la disciplina de asistencia en la toma de decisiones. En este contexto la decisión a tomar sería a qué sustancia asignar cada píxel de la imagen entre las que son factibles de presentarse. Para la implementación de los operadores lógicos difusos se utilizan las operaciones que sugiere la Lógica Compensatoria, que ha demostrado ser muy eficiente en este contexto de la toma de decisiones.

Se ha probado el sistema en imágenes de cerebro, para las que se encuentra gran cantidad de trabajos y técnicas desarrolladas específicamente, pero todo hace suponer que la idea no se agota en este tipo de imágenes, lo que dará lugar a futuros y prometedores trabajos.

2 MATERIALES Y MÉTODOS

2.1. Resonancia Magnética

Las imágenes de Resonancia Magnética se basan en el fenómeno físico de la resonancia magnética nuclear. Consiste en medir parámetros que caracterizan la transición entre los estados de núcleos de ciertas moléculas con contenido de Hidrógeno (principalmente agua) ante la presencia de un campo magnético externo. El retorno del núcleo a su equilibrio se caracteriza con dos tiempos denominados T1 y T2, que asociados con la densidad de protones (PD) son característicos de los diferentes tipos de tejidos o sustancias. La excitación se lleva a cabo con un pulso de radiofrecuencia (RF) a una frecuencia específica y está relacionado con el campo magnético externo.

Variando el campo magnético de una manera específica se produce un mapa de las ubicaciones espaciales de los núcleos y sus densidades. La imagen se logra luego de complejos procesos de detección, reconstrucción y transformaciones.

Las intensidades de la imagen dependen de los parámetros con que se haya configurado el scanner y de la secuencia de pulsos de RF. Pueden compararse las intensidades de diferentes imágenes solamente si se han mantenido estos parámetros constantes (Storey, 2006).

2.2. Lógica Difusa

La lógica difusa es una rama de la inteligencia computacional que se funda en la incertidumbre, lo cual permite manejar información vaga o de difícil especificación si se quiere utilizar objetivamente esta información con un fin específico (Kecman y Vojislav, 2001). Es una herramienta para modelar el conocimiento o la comprensión de conceptos.

La lógica difusa permite implementar un proceso por medio de predicados que generalmente se refieren a cantidades indefinidas o inciertas. Estos predicados pueden obtenerse con sistemas que “aprenden” al “procesar” datos reales o pueden también ser formulados por un experto humano o, mejor aún, por el consenso entre varios de ellos.

La flexibilidad de la Lógica Difusa la hace apropiada para los sistemas de asistencia en la toma de decisiones (Sousa et al. 2003; Li et al. 1995). Su capacidad para elaborar modelos lingüísticos la hacen muy útil para resolver problemas reales y brinda un esquema adecuado para una mejor comunicación con los que deben tomar las decisiones y los expertos.

Se han realizado estudios basados en lógica multivaluada en los que se han presentado diversos operadores para las operaciones entre valores de verdad de sentencias (o entre conjuntos difusos). Recientemente se ha propuesto un enfoque para aplicaciones de toma de decisiones con una capacidad práctica evidente, denominado Lógica Compensatoria (Espin Andrade, 2004), que ofrece nuevas operaciones para implementar los operadores lógicos conjunción y disyunción, entre otros.

La Lógica Difusa Compensatoria, es un sistema lógico que permite la modelación simultánea de los procesos deductivos y de toma de decisiones. Su uso en diversas aplicaciones (Delgado Fernandez, 2005; Espin Andrade y Vanti, 2005) ha demostrado la capacidad que presenta para tener en cuenta simultáneamente predicados o afirmaciones que hasta pueden ser contradictorios.

En los procesos que requieren toma de decisiones, el intercambio con los expertos lleva a obtener formulaciones complejas y sutiles que requieren de predicados compuestos. Los valores de verdad obtenidos sobre estos predicados compuestos deben poseer sensibilidad a los cambios de los valores de verdad de los predicados básicos. Esta necesidad se satisface con el uso de la Lógica Compensatoria, que renuncia al cumplimiento de las propiedades

clásicas de la conjunción y la disyunción, contraponiendo a éstas la idea de que el aumento o disminución del valor de verdad de la conjunción o la disyunción provocadas por el cambio del valor de verdad de una de sus componentes, puede ser “compensado” con la correspondiente disminución o aumento de la otra.

Se presentan a continuación los operadores propuestos por la Lógica Compensatoria.

La operación para la conjunción (“and”) está dada por:

$$c(x_1, x_2, \dots, x_n) = (x_1 x_2 \dots x_n)^{1/n} \quad (1)$$

La disyunción (“or”) se calcula mediante la siguiente expresión:

$$d(x_1, x_2, \dots, x_n) = 1 - [(1 - x_1)(1 - x_2) \dots (1 - x_n)]^{1/n} \quad (2)$$

En ambas ecuaciones, $x_i, i = 1, 2, \dots, n$ corresponde al valor de verdad de los predicados básicos que se relacionan mediante los operadores presentados.

Utilizando las definiciones anteriores y la operación de negación (“not”):

$$n(x) = 1 - x \quad (3)$$

pueden definirse otros importantes y útiles operadores. La implicación y la equivalencia se definen mediante las siguientes operaciones:

$$i(x, y) = d(n(x), c(x, y)) \quad (4)$$

$$e(x, y) = c(i(x, y), i(y, x)) \quad (5)$$

2.3. Lógica Difusa Compensatoria en procesamiento de imágenes de RM

Los médicos especialistas en diagnóstico por imágenes suelen explicar la interpretación de las imágenes de RM enunciando algunas consideraciones basadas en inspecciones visuales de esas imágenes que luego aplican de forma automática. Para explicar cómo reconocer regiones en las que se encuentra agua o algún líquido suelen enunciar sentencias del tipo “el líquido se ve negro en T1, blanco en T2”. Implícitamente lo que se está explicando es que, cuando se trata de agua, en la secuencia T1 se verán regiones “oscuras” y las mismas regiones se verán “claras” en la secuencia T2.

Se tienen entonces conceptos sencillos de interpretar visualmente, pero no adecuados para la implementación computacional con herramientas tradicionales de segmentación.

Los primeros cuestionamientos que surgen son: ¿qué intensidades de gris presentan las regiones de la imagen consideradas “negras” u “oscuras”? ¿Cuáles intensidades representan la idea de “blanco” o “brillante”?

En esta etapa resulta de suma importancia contar con imágenes previamente clasificadas, en lo posible por los mismos expertos que enuncian los predicados utilizados para la discriminación de las sustancias presentes, con el fin de hacer un análisis cuantitativo de estas ideas.

En una etapa inicial de este trabajo fue de utilidad, dado un conjunto de imágenes segmentadas previamente, la representación con histogramas de las intensidades de gris para las regiones reconocidas de las diferentes sustancias. Con estas representaciones puede comprenderse que las ideas expresadas, como por ejemplo “negro” o “blanco”, en realidad representan intervalos de intensidades de grises a veces con gran diversidad de valores. Esto se debe a la poca sensibilidad del ojo humano para detectar variaciones de intensidad pequeñas. Así es como, en el intervalo de valores de 0 a 255, los valores entre 0 y 20 son prácticamente iguales y visiblemente “negros” y los valores entre 230 y 255 son

prácticamente “blancos”.

De esta manera, a través de entrevistas con distintos expertos, investigando sobre distintos tipos de imágenes, reconociendo diferentes sustancias o tejidos en las imágenes, surgen cada vez más descripciones subjetivas, formales e informales, como por ejemplo “gris claro”, “intensidad constante”, “zonas brillantes”, “gris”, “gris intenso”, “regiones hipointensas”, “prácticamente negro”, “blanco”, “gris oscuro”, y todas sus combinaciones a través de conectivos lógicos.

La lógica difusa es un enfoque que suele resolver con éxito este tipo de situaciones, puesto que permite utilizar estas ideas expresadas lingüísticamente para efectuar cálculos matemáticos objetivos que reflejen el resultado razonado.

Para formalizar un proceso de cálculo se requiere expresar predicados diferentes para cada sustancia que se desea detectar en un determinado tipo de imágenes. En especial las imágenes de RM son interesantes para este enfoque por la riqueza de la complementariedad de información que presentan las distintas secuencias de adquisición.

En este trabajo se presenta un análisis de imágenes de RM píxel a píxel en el cual para cada sustancia a reconocer se ha definido un predicado que involucra las intensidades presentes en las secuencias T1, T2, y eventualmente, de ser necesaria, la secuencia PD en imágenes de cerebros. El objetivo es decidir a qué sustancia, dentro de las posibles, corresponde cada píxel de la imagen. Las sustancias a reconocer son: líquido cefalorraquídeo (CSF, *Cerebro Spinal Fluid*), materia gris (GM, *Gray Matter*), materia blanca (WM, *White Matter*) y se ha agregado un predicado explícito para el fondo.

Se ha determinado el siguiente conjunto de predicados que describen las sustancias, establecido en conjunto con los expertos y expresados lingüísticamente:

P1: El líquido cefalorraquídeo es *Oscuro* en T1, *MuyIntenso* en T2 y *MuyIntenso* en PD o también puede ser *Blanco* en T2.

P2: La materia gris es *Gris* en T1, *Intenso* en T2 y *MuyIntenso* pero *No-Blanco* en PD.

P3: La materia blanca es *Intenso* en T1, *Gris* en T2 e *Intenso* en PD.

P4: El fondo es *Negro* en T1 y *Negro* en T2.

Formalizando la expresión lingüística del Predicado 1 se tendrá:

“el píxel corresponde a CSF” cuando “el píxel es *Oscuro* en T1” y “el píxel es *MuyIntenso* o *Blanco* en T2” y “el píxel es *MuyIntenso* en PD”.

$$\mu A = \mu B \text{ AND } (\mu C \text{ OR } \mu D) \text{ AND } \mu E$$

donde:

A = “el píxel representa CSF”

B = “el píxel es *Oscuro* en T1”

C = “el píxel es *MuyIntenso* en T2”

D = “el píxel es *Blanco* en T2”

E = “el píxel es *MuyIntenso* en PD”

μX = grado de verdad de la sentencia X.

El valor de verdad logrado en cada predicado no debe ser tomado como absoluto, sino que intervendrá como resultado parcial en la toma de decisión de la sustancia que se asignará a cada píxel. Tal es el uso apropiado de la lógica compensatoria (Espín Andrade et al. 2004).

El procesamiento de la imagen consiste en un análisis de la misma píxel a píxel donde para cada uno se toma la decisión de la asignación a alguna de estas sustancias.

Si un píxel correspondiera en realidad a una sustancia no descrita en los predicados anteriores, igualmente sería clasificado o reconocido como de una de ellas, pero en estos casos puede ser factible determinar que la clasificación no es demasiado confiable, dado que los valores de verdad hallados para todos los predicados serán pequeños, menores a un cierto umbral de tolerancia determinado. Debe tenerse presente que se está haciendo una asignación de las sustancias “explicadas” en los predicados y que no se busca encontrar nuevo conocimiento o agrupar los píxeles en diferentes clases como suele hacerse con la aplicación de otras técnicas.

Para efectuar la cuantificación de los valores de verdad de los predicados se definieron conjuntos difusos sobre el rango de valores de gris (de 0 a 255).

Tomando algunas imágenes previamente clasificadas, se armaron vectores de intensidades de grises a los que corresponde cada una de las sustancias a detectar. Así se pudo observar los rangos de intensidades entre los que se encontraba cada sustancia en cada secuencia (T1, T2 o PD).

En la [Figura 1](#) pueden verse los histogramas correspondientes a las secuencias T1, T2 y PD para el WM (a), GM (b) y CSF (c). Puede concluirse que el CSF se encuentra mayormente en el rango de intensidades entre 20 y 60 para la secuencia T1, pero también hay unos pocos píxeles con intensidades entre 10 y 20 o entre 60 y 75.

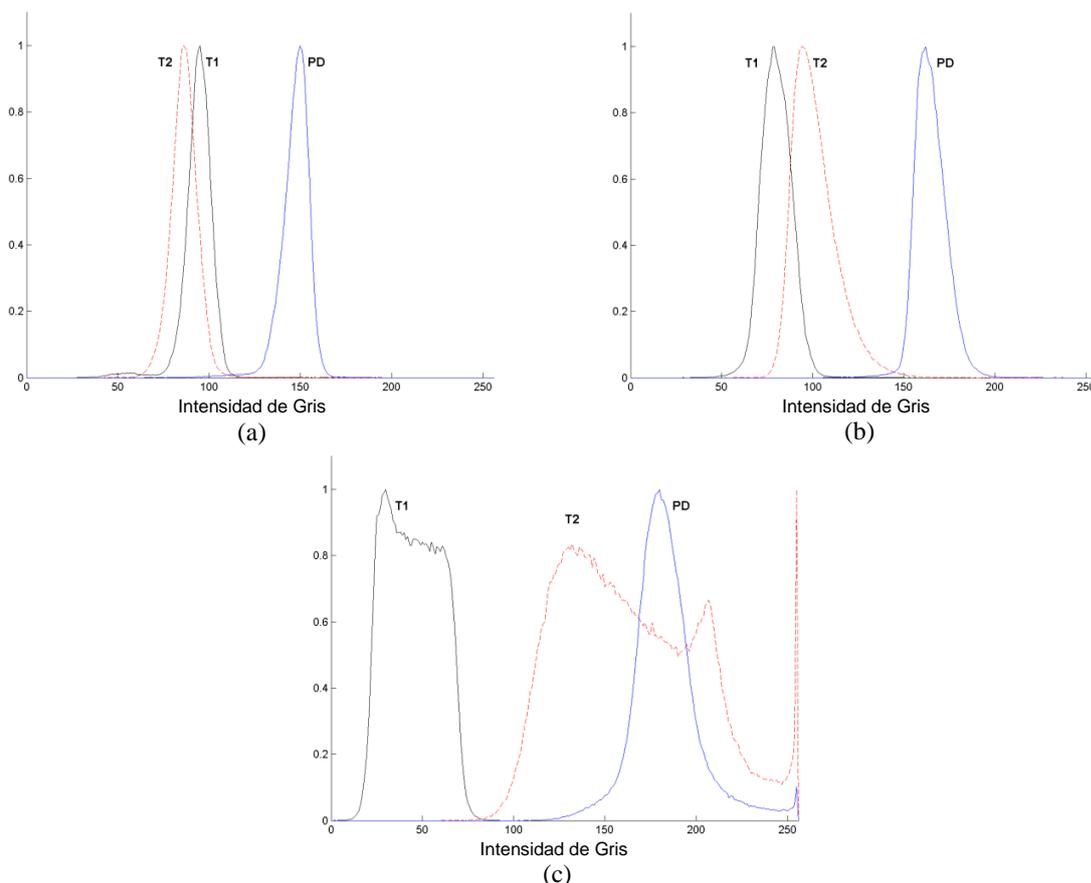


Figura 1: Histogramas de frecuencias relativas correspondientes a las intensidades de gris de las secuencias T1, T2 and PD correspondientes a sustancia blanca (a), sustancia gris (b) y líquido cefalorraquídeo (c).

De los expertos se tenía el conocimiento de que el CSF se ve “oscuro en T2”, por lo que de este análisis surge que el concepto “oscuro” (un conjunto difuso) en este contexto podría ser

representado por la función de pertenencia que se visualiza en la [Figura 2](#), indicado con la etiqueta “*Oscuro*”. Así puede completarse el análisis para cada conjunto difuso que aparezca en cada uno de los predicados enunciados.

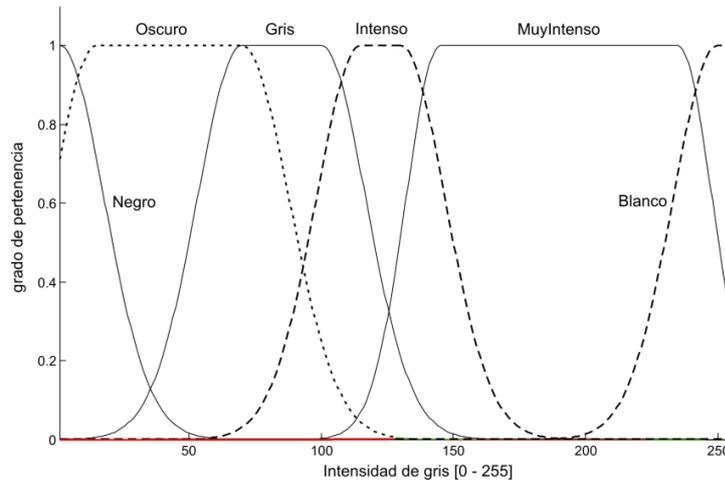


Figura 2: Funciones de pertenencia para definir los conjuntos difusos “Negro”, “Oscuro”, “Gris”, “Intenso”, “MuyIntenso”, y “Blanco”..

Las funciones de pertenencia obtenidas se simbolizan mediante: $\mu_{NEGRO}(x)$, $\mu_{OSCURO}(x)$, $\mu_{GRIS}(x)$, $\mu_{INTENSO}(x)$, $\mu_{MUY-INTENSO}(x)$, $\mu_{BLANCO}(x)$ donde $x \in 0,255$ representa el valor de intensidad de gris.

La función de pertenencia que define el conjunto difuso “*Negro*” es de tipo “Z”. Esta función requiere 2 parámetros (a y b) para quedar determinadas su posición y forma:

$$\mu_{NEGRO}(x) = \begin{cases} 1 & x \leq a \\ 1 - 2 \frac{x-a}{b-a}^2 & a \leq x \leq \frac{a+b}{2} \\ 2 \frac{b-x}{b-a}^2 & \frac{a+b}{2} \leq x \leq b \\ 0 & x \geq b \end{cases} \quad (6)$$

La función que define el conjunto difuso “*Blanco*” es de tipo “S”, también con 2 parámetros requeridos, y su expresión es la siguiente:

$$\mu_{BLANCO}(x) = \begin{cases} 0 & x \leq a \\ 2 \frac{b-x}{b-a}^2 & a \leq x \leq \frac{a+b}{2} \\ 1 - 2 \frac{b-x}{b-a}^2 & \frac{a+b}{2} \leq x \leq b \\ 1 & x \geq b \end{cases} \quad (7)$$

Las otras funciones de pertenencia son de tipo gaussianas asimétricas. Éstas permiten que en un determinado intervalo de grises, los grados de pertenencia tomen el valor máximo y luego descendan en forma suave. Estas funciones requieren 4 parámetros cada una para quedar determinadas, e indican los puntos de comienzo de descenso y la velocidad del mismo (2 para el lado derecho y 2 para el lado izquierdo). La expresión es la siguiente:

$$\mu_{GRIS}(x) = \begin{cases} e^{-\frac{x-C_1}{2\sigma_1^2}} & x \leq C_1 \\ 1 & C_1 \leq x \leq C_2 \\ e^{-\frac{x-C_2}{2\sigma_2^2}} & x \geq C_2 \end{cases} \quad (8)$$

Algunas sustancias pueden requerir predicados más complejos para su reconocimiento, lo que no implica un problema puesto que la lógica difusa permite operar con cualquier conector lógico o implicaciones. El conector más usado en este caso es AND para relacionar lo que presentan las imágenes T1, T2 y PD.

Una vez obtenidas funciones de pertenencia adecuadas, se procede al análisis de la imagen píxel a píxel. Dado un píxel con una intensidad x , la primera operación a efectuar es la obtención de un valor difuso entre 0 y 1 para cada uno de los conjuntos difusos que se aplicarán (“Gris”, “Intenso”, “Negro”, “Blanco”, etc.) mediante las ecuaciones (6), (7) y (8). Luego se debe calcular el valor también difuso de las operaciones lógicas realizadas entre los predicados básicos que forman el predicado compuesto que describe a cada sustancia.

Por ejemplo, para asignar un valor de verdad a la expresión “el píxel corresponde a materia blanca” (P3) se analizaría el grado de verdad de μ_1 = “el píxel es *Intenso* en T1”, μ_2 = “el píxel es *Gris* en T2” y μ_3 = “el píxel es *Intenso* en PD” a través de las funciones de pertenencia. Estos grados de verdad se combinarían con la operación AND para lograr un valor final mediante la expresión:

$$c(\mu_1, \mu_2, \mu_3) = (\mu_1 \mu_2 \mu_3)^{1/3} \quad (9)$$

El procedimiento se repite para cada uno de los predicados correspondientes a las distintas sustancias. Finalmente el píxel se asigna a la sustancia con mayor valor de verdad.

2.4. Implementación del método

Primeramente se arreglan en vectores los valores de intensidades de grises de las imágenes a analizar, donde cada elemento representa un píxel de la imagen. Luego se calculan los valores de pertenencia de todos los píxeles a los diferentes conjuntos difusos que intervienen en los predicados. Se efectúan las operaciones lógicas que indican los predicados para cada una de las sustancias para determinar su grado de verdad y tomar el mayor de ellos. Finalmente se construye una imagen que muestre diferentes colores según la sustancia indicada.

A continuación se presenta la formalización del método:

Sea \mathbf{X} un vector de dimensión N cuyos elementos son las intensidades de gris de la imagen \mathbf{Y} :

$$\mathbf{X}_Y = [i_1 \ i_2 \ \dots \ i_N]^T \quad (10)$$

N representa la cantidad de píxeles a analizar. Por ejemplo, si se trabaja con imágenes de 256 x 256 píxeles, $N = 65536$.

Sean tres vectores: X_{T1} , X_{T2} and X_{PD} , definidos para representar las imágenes T1, T2 y PD. La pertenencia a cada conjunto difuso se calcula como:

$$\mu_{fuzzySet}(\mathbf{X}_Y) = m_{fuzzySet}(\mathbf{X}_Y) \quad (11)$$

donde $m_{fuzzySet}$ es la expresión de la función de pertenencia que define el conjunto difuso “*fuzzySet*” y \mathbf{X}_Y es el vector de cualquiera de las imágenes consideradas. Se calculan tantos

vectores $\mu_{fuzzySet}$ (también de dimensión N) como conjuntos difusos se utilicen en los predicados.

Los valores de verdad de los K predicados se calculan operando con las pertenencias a los conjuntos difusos recién calculadas. Las operaciones serán diferentes, dependiendo de las definiciones de los predicados.

Ejemplo #1: el predicado P1 declara que “El Tejido TEJ1 es *Intenso* en T1, es *Oscuro* en T2 y es *MuyIntenso* en PD”. Usando Lógica Compensatoria, se calcula la siguiente operación de conjunción (c):

$$\begin{aligned} \mu_{P1} &= c\left(\mu_{Intenso}(X_{T1}), \mu_{Oscuro}(X_{T2}), \mu_{MuyIntenso}(X_{PD})\right) \\ &= \left[\mu_{Intenso}(X_{T1}) \times \mu_{Oscuro}(X_{T2}) \times \mu_{MuyIntenso}(X_{PD})\right]^{\frac{1}{3}} \end{aligned} \quad (12)$$

Ejemplo #2: el predicado P2 declara que “El Tejido TEJ2 es *Gris* en T1, es *Blanco* o *MuyIntenso* en T2 y es *Intenso* en PD”. En este caso se calcula la siguiente operación de conjunción (c) y disyunción (d):

$$\begin{aligned} \mu_{P2} &= c\left(\mu_{Gris}(X_{T1}), d\left(\mu_{Blanco}(X_{T2}), \mu_{MuyIntenso}(X_{T2})\right), \mu_{Intenso}(X_{PD})\right) \\ &= \left[\mu_{Gris}(X_{T1}) \times \mu_{Intenso}(X_{PD}) \times \sqrt{(1 - \mu_{Blanco}(X_{T2})) \times (1 - \mu_{MuyIntenso}(X_{T2}))}\right]^{\frac{1}{3}} \end{aligned} \quad (13)$$

Finalmente, se construye una nueva matriz A de dimensión $N \times K$ con esos vectores. Cada columna será un vector de grados de verdad, correspondiendo a los K predicados.

$$A = [\mu_{P1} \mu_{P2} \dots \mu_{PK}] \quad (14)$$

El objetivo de la matriz A es hallar la columna que contiene el máximo valor, operando fila por fila. El índice de la columna que contiene el máximo identifica al tejido que será asignado. Los resultados se almacenan en un nuevo vector D , también de N elementos.

$$D = indiceColMax(A) \quad (15)$$

donde la operación indicada como *indiceColMax* indica hallar el índice de la columna que contiene el valor máximo de cada fila.

Finalmente, el vector D se reacomoda para construir una matriz del mismo tamaño de la imagen original, y contiene la clasificación obtenida. Los valores de esta matriz son los índices que identifican los tejidos, siendo éstos enteros entre 1 y K .

Todo el sistema fue implementado en MatLab R13[®]. Los operadores de Lógica Compensatoria, fueron programados para esta aplicación.

En la etapa de prueba se diseñó una interfaz gráfica para testear, eligiendo un píxel por un operador: los valores de gris, las pertenencias a los diferentes conjuntos difusos y los valores de verdad de los predicados que definen a cada sustancia. Luego se automatizó el proceso completo.

Para comparar este método con alguna referencia conocida se tomaron algunas imágenes que habían sido segmentadas mediante el software BRAINS (Mental Health Clinical Research Center, Universidad de Iowa). Se utilizó el Coeficiente de Tanimoto (TC) (Duda et al. 2000), que tomaría el valor 1 cuando la segmentación lograda coincide totalmente con la de referencia.

2.5. Validación del método

El método propuesto se evaluó primeramente con imágenes provenientes de la Base de Datos del Montréal Neurological Institute (Simulated Brain Database), McGill University (Montréal Neurological Institute, 2007). Esto permitió evaluar la robustez del método en cuanto al ruido y a las no-uniformidades en la intensidad, utilizando imágenes con diferentes niveles de ruido y diferentes intensidades de no-uniformidades.

Para evaluar el método con imágenes reales, se utilizaron estudios coronales obtenidos de la Clínica de Demencia del Instituto de Investigaciones Neurológicas “Raúl Carrea”. Las imágenes se clasificaron previamente con el software BRAINS, suministrado por el Centro de Investigaciones Clínicas en Salud Mental de la Universidad de Iowa. Cuando aparecieron discrepancias, las imágenes clasificadas fueron corregidas manualmente a través de trabajo minucioso de médicos especialistas en imágenes. Las clasificaciones así obtenidas se utilizaron como *Gold Standard* para evaluar la exactitud del método.

Las imágenes de RM se adquirieron en un equipo de 1.5 Tesla. El protocolo incluyó cortes coronales 3D pesados en T1 con ecos ortogonales a la línea AC-PC (TR/TE= 24/5 ms, ancho de corte = 1.5 mm); y cortes coronales pesados en PD y T2 con ecos de spin rápidos (TR/TE!/TE= 3,500/32/96 ms, echo train length = 8, ancho de corte = 3 mm).

En todos los casos, las imágenes se pre-procesaron para remover las regiones de tejidos indeseados, principalmente el cráneo. Se aplicó un procedimiento previamente desarrollado, basado en morfología matemática y distancia geodésica (Pastore et al. 2005).

Se probó el método en 15 imágenes 3D con tamaño de 256x256x192 píxeles.

Para evaluar la calidad de la segmentación obtenida, se empleó el Coeficiente de Tanimoto (TC, *Tanimoto Coefficient*), que ha sido ampliamente utilizado en aplicaciones similares a la presente (Jimenez-Alaniz et al. 2006; Song et al. 2004). La definición de este coeficiente es (Duda et al. 2000):

$$TC_{XY}(k) = \frac{n_{X \cap Y}(k)}{n_{X \cup Y}(k)} \quad (16)$$

donde \mathbf{X} es una imagen binaria que contiene los píxeles identificados como del tejido k , \mathbf{Y} es una imagen binaria de la segmentación de referencia para el tejido k , y $n_x(k)$ es la cantidad de píxeles de la imagen \mathbf{X} que corresponden al tejido k . Este valor se calcula para cada tejido. Cuando la segmentación es perfecta, el coeficiente toma el valor 1.

3 RESULTADOS

Aplicando este método de segmentación basado en predicados con valores de verdad difusos se ha logrado discriminar exitosamente la sustancia gris, la sustancia blanca y el fluido cerebroespinal en estudios de RM de cerebro. Se probó el método en 3 estudios completos de 192 imágenes cada uno, de 256x256 píxeles de tamaño.

En las Figuras 3a y 3c se muestran como ejemplos imágenes corte coronal, secuencia T2 y en las Figuras 3b y 3d se observan los respectivos resultados aplicando el método propuesto con diferentes colores para cada tejido detectado.

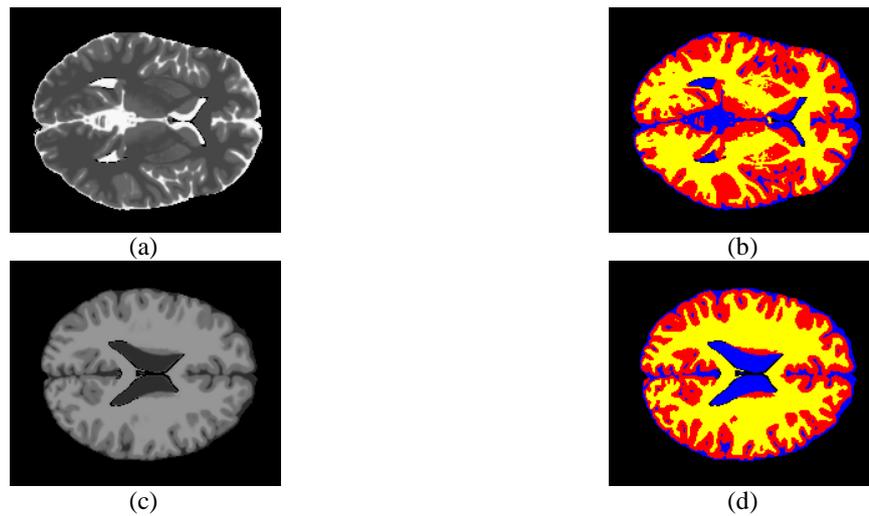


Figura 2: Cortes T2 (a,c) y resultados del reconocimiento de tejidos obtenido (b, d) para sustancia blanca (amarillo), sustancia gris (rojo) y líquido cefalorraquídeo (azul).

Las operaciones involucradas son sencillas, por lo que los tiempos de cálculo son cortos, lo que hace el método adecuado para estudios completos en los que se requiere el procesamiento de gran cantidad de cortes.

Los valores obtenidos para el TC en las imágenes simuladas fueron superiores a 0.78 para todas las sustancias, aun en las peores condiciones de nivel de ruido y de no-uniformidad en la intensidad, lo que permite asegurar en principio que el método funciona aceptablemente y con una gran robustez. Cuando se probó el método con imágenes sin distorsiones el TC tomó siempre valores superiores a 0.94.

Las segmentaciones de imágenes reales obtenidas fueron primeramente comparadas con las obtenidas por el software BRAINS. Posteriormente estas imágenes fueron evaluadas minuciosamente por los mismos expertos que sugirieron los predicados para la detección de las sustancias. Todos ellos coincidieron en que la clasificación obtenida es la esperada según su experiencia, lo que avala la realización de posteriores cálculos con las imágenes segmentadas. Esta evaluación subjetiva es importante en este contexto, pues asegura que los expertos, quienes serían los usuarios del sistema implementado, tendrían confianza en los resultados entregados por el mismo.

El tiempo de cálculo es relativamente corto. Un estudio típico 3D de 180 cortes se efectúa en aproximadamente 3 minutos en una PC actual estándar (Procesador Pentium IV de 3 GHz, 1 Gb de memoria RAM, Disco Rígido de 160 Gb).

4 DISCUSIÓN

Para esta aplicación específica (imágenes de RM), los predicados que definen los tejidos a reconocer podrían involucrar otras características mas allá de los niveles de gris en las imágenes. Podrían incorporarse características de texturas tales como rugosidad o inclusive nivel de ruido o cualquiera que pueda ser cuantificable.

A través del cálculo del TC se aseguró la robustez del método. Los valores del TC son inclusive muy buenos en presencia de ruido o no-uniformidades en la intensidad.

Dada la simplicidad de las operaciones involucradas, el sistema puede ser programado en cualquier lenguaje sin necesidad de motores de cálculo ni cualquier otra librería específica. Cualquier lenguaje que manipule eficientemente vectores y matrices será adecuado. En esta etapa aún no se ha optimizado el código. Sin embargo sólo con compilarlo en un lenguaje de más bajo nivel que MatLab[®] se lograría una apreciable reducción de los tiempos de procesamiento. Tampoco se debiera despreciar la posibilidad de implementarlo en hardware de manera de obtener una herramienta en tiempo real.

La segmentación de las imágenes de RM es muy útil tanto para mejorar los informes de rutina como para poder discernir entre valores normales y patológicos de las diferentes estructuras presentes.

Como trabajo futuro se proponen dos líneas específicas: la optimización de los parámetros de las funciones de pertenencia mediante algoritmos genéticos, utilizando también lógica compensatoria para su función de evaluación y la incorporación de modificadores a los conjuntos difusos (“muy”, “poco”, “algo”) que definen los predicados. Estas contribuciones mejorarían la exactitud del sistema (TC aún más cercanos a 1). Ya se han realizado algunos avances en ese sentido que se encuentran en etapa de prueba y se han obtenido resultados preliminares alentadores.

Un post-procesamiento adicional podría considerar aisladamente los píxeles que tienen como resultado del grado de verdad de todos los predicados valores inferiores a 0.5. En este caso podría tratarse de sustancias no indicadas en los predicados y estos píxeles deberían rotularse como tales.

5 CONCLUSIONES

Este trabajo presenta un método para segmentar tejidos en imágenes de RM basado en Lógica Difusa, aplicando los operadores de la Lógica Compensatoria para el cálculo de las operaciones difusas.

El sistema implementa en forma computacional el conocimiento que brindan los expertos a la hora de interpretar las imágenes de RM en forma de predicados lógicos compuestos.

Como las operaciones involucradas son sencillas, los tiempos de cálculo son cortos, lo que hace al método adecuado para estudios completos en los que deben segmentarse gran cantidad de imágenes.

El método resulta robusto respecto al ruido y a las no-uniformidades en la intensidad. Además resulta prometedor para aplicaciones en otros tipos de imágenes con una mayor cantidad de sustancias a reconocer.

Dada la relativa sencillez de los cálculos a efectuar, este sistema puede ser programado en cualquier lenguaje sin requerir grandes motores de cálculo ni librerías especiales. En general es adecuado cualquier lenguaje que pueda trabajar eficientemente con vectores.

La segmentación de las imágenes es importante en posteriores cuantificaciones para la presentación de informes y sobretodo a la hora de discernir entre valores normales y patológicos de las diferentes estructuras presentes.

6 AGRADECIMIENTOS

Los autores quieren expresar su agradecimiento al Dr. Carlos Capiel y al Dr. Sebastián Costantino, del Instituto Radiológico de Mar del Plata (Buenos Aires, Argentina), por brindar su tiempo y experiencia para llevar adelante esta investigación.

REFERENCIAS

- MNI's BrainWeb dataset: <http://www.bic.mni.mcgill.ca/brainweb/>. Montréal Neurological Institute, McGill University, 2007.
- Abras, G., Ballarin, V. L. y González, M. Aplicación de Reconocimiento de Patrones en la Clasificación de Tejido Cerebral. Proceedings of Congreso Argentino de Bioingeniería, 2001.
- Alfano, B., Brunetti, A., Covelli, E. M., Quarantelli, M., Panico, M. R., Ciarmiello, A. y Salvatore, M. Unsupervised, automated segmentation of the normal brain using a multispectral relaxometric magnetic resonance approach. *Magn Reson Med*, 37(1):84-93, 1997.
- Ashburner, J. y Friston, K. J. Voxel-based morphometry--the methods. *Neuroimage*, 11(6 Pt 1):805-821, 2000.
- Bartlett, T. Q., Vannier, M. W., McKeel, D. W., Jr., Gado, M., Hildebolt, C. F. y Walkup, R. Interactive segmentation of cerebral gray matter, white matter, and CSF: photographic and MR images. *Comput Med Imaging Graph*, 18(6):449-460, 1994.
- Bezdek, J. C., Hall, L. O. y Clarke, L. P. Review of MR image segmentation techniques using pattern recognition. *Med Phys*, 20(4):1033-1048, 1993.
- Chen, S., Wei-chun, L. y Chen, C. Medical image understanding system based on Dempster-Shafer reasoning. Proceedings of SPIE, 1445: 386, 1991.
- Clarke, L. P., Velthuizen, R. P., Hall, L. O., Bezdek, J. C., Bensaid, A. M., Silbiger, M. L. y Clarke, L. P. Comparison of supervised pattern recognition techniques and unsupervised methods for MRI segmentation. Proceedings of SPIE, 1652: 668-677, 1992.
- Cocosco, C. A., Zijdenbos, A. P. y Evans, A. C. A fully automatic and robust brain MRI tissue classification method. *Med Image Anal*, 7(4):513-527, 2003.
- Collins, D., Montagnat, J., Zijdenbos, A., Evans, A. y Arnold, D. Automated estimation of brain volumen in multiple sclerosis with BICCR. Proceedings of IPMI: Information Processing in Medical Imaging, 2082 of LNCS: 141-147, 2001.
- Delgado Fernández, T. Capacity-building: spatial data infrastructure readiness index - Formación de capacidades: índice de alistamiento para infraestructuras de datos espaciales - IDE. Proceedings of 8th UN Regional Cartographic Conference for the Americas, 27 de junio al 1° de julio, 2005.
- Denkowski, M., Chlebiej, M. y Mikolajczak, P. Segmentation of human brain MR images using rule-based fuzzy logic inference. *Stud Health Technol Inform*, 105:264-272, 2004.
- Di Bona, S., Niemann, H., Pieri, G. y Salvetti, O. Brain volumes characterisation using hierarchical neural networks. *Artif Intell Med*, 28(3):307-322, 2003.
- Duda, R. O., Hart, P. E. y Stork, D. G. Pattern Classification. Wiley Interscience, 2000.
- Espín Andrade, R. A., Marx Gómez, J., Mazcorro Téllez, G. y Fernández González, E. Compensatory Logic: A Fuzzy Approach to Decision Making. Proceedings of 4th International Symposium on Engineering of Intelligent Systems (EIS' 2004), June 2004, 2004.
- Espín Andrade, R. A. y Vanti, A. A. Administración Lógica: Un estudio de caso en una empresa de Comercio Exterior. *Revista BASE*, 2(2):69-77, 2005.

- Gerig, G., Martin, J., Kikinis, R., Kubler, O., Shenton, M. y Jolesz, F. A. Unsupervised tissue type segmentation of 3D dual-echo MR head data *Image Vision Comput.* , 10(6):349-360 1992.
- Germond, L., Dojat, M., Taylor, C. y Garbay, C. A cooperative framework for segmentation of MRI brain scans. *Artif Intell Med*, 20(1):77-93, 2000.
- Jimenez-Alaniz, J. R., Medina-Banuelos, V. y Yanez-Suarez, O. Data-driven brain MRI segmentation supported on edge confidence and a priori tissue information. *IEEE Trans Med Imaging*, 25(1):74-83, 2006.
- Kecman, V. *Learning and Soft Computing - Support Vector Machines, Neural Networks and Fuzzy Logic Models*. The MIT Press, 2001.
- Li, H.-X. y Yen, V. C. *Fuzzy Sets and Fuzzy Decision-Making*. CRC Press, 1995.
- Marroquin, J. L., Vemuri, B. C., Botello, S., Calderon, F. y Fernandez-Bouzas, A. An accurate and efficient bayesian method for automatic segmentation of brain MRI. *IEEE Trans Med Imaging*, 21(8):934-945, 2002.
- Pastore, J. I., Moler, E. G. y Ballarin, V. L. Segmentation of brain magnetic resonance images through morphological operators and geodesic distance. *J Digital Signal Processing*, 15(2):153-160, 2005.
- Richard, N., Dojat, M. y Garbay, C. Automated segmentation of human brain MR images using a multi-agent approach. *Artif Intell Med*, 30(2):153-175, 2004.
- Shen, S., Sandham, W., Granat, M. y Sterr, A. MRI fuzzy segmentation of brain tissue using neighborhood attraction with neural-network optimization. *IEEE Trans Inf Technol Biomed*, 9(3):459-467, 2005.
- Siromoney, A., Raghuram, L., Siromoney, A., Korah, I. y Prasad, G. N. Inductive logic programming for knowledge discovery from MRI data. *IEEE Eng Med Biol Mag*, 19(4):72-77, 2000.
- Song, T., Angelini, E., Mensh, B. y Laine, A. Comparison study of clinical 3D MRI brain segmentation evaluation. *Conf Proc IEEE Eng Med Biol Soc*, 3:1671-1674, 2004.
- Sousa, J. M. C. y Kaymak, U. *Fuzzy Decision Making in Modeling and Control*. World Scientific, 2003.
- Storey, P. *Introduction to magnetic resonance imaging and spectroscopy*. *Methods Mol Med*, 124:3-57, 2006.
- Zadeh, L. A. The concept of a linguistic variable and its applications to approximate reasoning, I,II,III. *Inform. Sci.*, 8:199-249, 1974.
- Zeng, X., Staib, L. H., Schultz, R. T. y Duncan, J. S. Segmentation and measurement of the cortex from 3-D MR images using coupled-surfaces propagation. *IEEE Trans Med Imaging*, 18(10):927-937, 1999.
- Zhang, Y., Brady, M. y Smith, S. Segmentation of brain MR images through a hidden Markov random field model and the expectation-maximization algorithm. *IEEE Trans Med Imaging*, 20(1):45-57, 2001.